



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA ELEKTROTECHNIKY
A KOMUNIKAČNÍCH TECHNOLOGIÍ**

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV TELEKOMUNIKACÍ

DEPARTMENT OF TELECOMMUNICATIONS

**VÝVOJ MODERNÍCH AKUSTICKÝCH PARAMETRŮ
KVANTIFIKUJÍCÍCH HYPOKINETICKOU DYSARTRII**

DEVELOPMENT OF MODERN ACOUSTIC FEATURES QUANTIFYING HYPOKINETIC DYSARTHRIA

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Alexander Kowolowski

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Zoltán Galáž

BRNO 2019

Diplomová práce

magisterský navazující studijní obor **Audio inženýrství**

Ústav telekomunikací

Student: Bc. Alexander Kowolowski

ID: 175592

Ročník: 2

Akademický rok: 2018/19

NÁZEV TÉMATU:

Vývoj moderních akustických parametrů kvantifikujících hypokinetickou dysartrii

POKYNY PRO VYPRACOVÁNÍ:

V rámci diplomové práce budou navrženy a implementovány nové sofistikované akustické parametry kvantifikující poruchy řeči vyskytující se u pacientů trpících hypokinetickou dysartrií. Parametry budou popisovat zejména hybnost artikulačních orgánů, melodii, pauzování a tempo řeči. Budou také navrženy tzv. globální parametry, které budou popisovat kombinaci poruch v oblasti artikulace a prozodie řeči. Tyto parametry budou otestovány na nahrávkách řeči pacientů s Parkinsonovou nemocí.

DOPORUČENÁ LITERATURA:

[1] PELED, Abraham. Digital signal processing: theory, design, and implementation. New York: John Wiley, 1976.

[2] HERNITER, Marc E. Programming in MATLAB. Pacific Grove, CA: Brooks/Cole-Thomson Learning, 2001. ISBN 0534368808.

Termín zadání: 1.2.2019

Termín odevzdání: 16.5.2019

Vedoucí práce: Ing. Zoltán Galáž

Konzultant:

prof. Ing. Jiří Mišurec, CSc.
předseda oborové rady

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Abstrakt

Tato práce se zabývá návrhem a testováním nových akustických parametrů pro zpracování dysprozodické řeči u pacientů trpících hypokinetickou dysartrií. V práci je uvedeno a otestováno 41 nových parametrů pro kvantifikaci prozodie, tzn. popisujících melodii, hlasitost, rytmus a tempo řeči. Nové parametry by se daly rozdělit do sedmi skupin. V rámci skupin se parametry liší především použitými statistickými veličinami. První čtyři skupiny jsou založeny na absolutních diferencích a kumulativních součtech základního kmitočtu a krátkodobé energie signálu. Pátá skupina obsahuje parametry založené na násobku základního kmitočtu a krátkodobé energie do jednoho globálního intonačního parametru. Šestá skupina obsahuje globální časové parametry, které jsou poměry konvenčních rytmických a konvenčních tempových parametrů. Poslední skupina pak obsahuje globální parametry pro kvantifikaci celé prozodie, což jsou poměry globálních intonačních a globálních časových parametrů. Všechny parametry byly testovány na české databázi řečníků s Parkinsonovou nemocí PARCZ. Pro jednotlivé parametry byly nejdříve vykresleny grafy hustoty pravděpodobnosti. Následně byla provedena korelační analýza s dostupnými medicínskými škálami, nejprve pro všechny, poté jen v rámci globálních parametrů. Dále byla provedena klasifikační a regresní analýza s novými parametry pomocí klasifikačních a regresních stromů. Tato analýza byla provedena nejdříve pro jednotlivé nové parametry, poté pro všechna data všech parametrů najednou, a nakonec byl proveden sekvenční výběr nejlepší kombinace parametrů pro danou problematiku. I když nevyšel jeden určitý parametr jako jasný favorit celé diplomové práce, bylo pár parametrů, které se mezi nejlépe vycházejícími objevovaly opakovaně, a také se u některých testů objevil trend, že mezi nejlepším a druhým nejlepším parametrem byl větší rozdíl než mezi jinými v pořadí, dalo by se tedy hovořit o parametrech, které byly pro danou analýzu mnohem lepší než ostatní testované. Konkrétní výsledky a diskuze jsou obsaženy v závěru.

Klíčová slova

Databáze PARCZ, dysprozodie, hypokinetická dysartrie, klasifikační analýza, klasifikační a regresní stromy, korelační analýza, křížová validace, odhad hustoty pravděpodobnosti, parametry pro kvantifikaci dysprozodie, Parkinsonova nemoc, regresní analýza, sekvenční výběr parametrů, statistické veličiny, zpracování řečových signálů.

Abstract

This work deals with designing and testing of new acoustic features for analysis of dysprosodic speech occurring in hypokinetic dysarthria patients. 41 new features for dysprosody quantification (describing melody, loudness, rhythm and pace) are presented and tested in this work. New features can be divided into 7 groups. Inside the groups, features vary by the used statistical values. First four groups are based on absolute differences and cumulative sums of fundamental frequency and short-time energy of the signal. Fifth group contains features based on multiples of this fundamental frequency and short-time energy combined into one global intonation feature. Sixth group contains global time features, which are made of divisions between conventional rhythm and pace features. Last group contains global features for quantification of whole dysprosody, made of divisions between global intonation and global time features. All features were tested on Czech Parkinsonian speech database PARCZ. First, kernel density estimation was made and plotted for all features. Then correlation analysis with medicinal metadata was made, first for all the features, then for global features only. Next classification and regression analysis were made, using classification and regression trees algorithm (CART). This analysis was first made for all the features separately, then for all the data at once and eventually a sequential floating feature selection was made, to find out the best fitting combination of features for the current matter. Even though none of the features emerged as a universal best, there were a few features, that were appearing as one of the best repeatedly and also there was a trend that there was a bigger drop between the best and the second best feature, marking it as a much better feature for the given matter, than the rest of the tested. Results are included in the conclusion together with the discussion.

Keywords

Classification analysis, classification and regression trees, correlation analysis, cross validation, dysprosody, features for dysprosody quantification, hypokinetic dysarthria, kernel density estimation, PARCZ database, Parkinson's disease, regression analysis, sequential floating feature selection, speech signal processing, statistics.

KOWOLOWSKI, Alexander. *Vývoj moderních akustických parametrů kvantifikujících hypokinetickou dysartrii*. Brno, 2019. Dostupné také z: <https://www.vutbr.cz/studenti/zav-prace/detail/118146>. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav telekomunikací. Vedoucí práce Zoltán Galáž.

Prohlášení o původnosti

Prohlašuji, že svou diplomovou práci na téma Vývoj moderních akustických parametrů kvantifikujících hypokinetickou dysartrii jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních anebo majetkových a jsem si plně vědom následku porušení ustanovení § 11 a následujících autorského zákona č.121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne 16. 5. 2019

.....
podpis autora

Poděkování

Tímto bych chtěl poděkovat svému vedoucímu Ing. Zoltánovi Galážovi Ph.D. za to, že mi umožnil podílet se na řešení této problematiky, a také za cenné rady a přátelský přístup.

V Brně dne 16. 5. 2019

.....
podpis autora

Obsah

Seznam obrázků	9
Seznam tabulek	10
Úvod	11
1 Parkinsonova nemoc.....	12
1.1 Historie	12
1.2 Vznik Parkinsonovy nemoci	13
1.3 Stádia a symptomy Parkinsonovy nemoci.....	14
1.3.1 Příznaky v prvních stádiích nemoci	15
1.3.2 Příznaky v pokročilých stádiích nemoci.....	15
2 Hypokinetická dysartrie.....	16
2.1 Dysprozodie	16
3 Analýza řeči pacientů s dysartrií.....	17
3.1 Test 3F.....	17
4 Konvenční parametry kvantifikující dysprozodii	19
5 Nové parametry kvantifikující dysprozodii	21
5.1 Nové intonační parametry.....	21
5.2 Nové časové parametry	24
5.3 Globální parametry.....	25
6 Výsledky	26
6.1 Databáze PARCZ.....	26
6.2 Výpočet nových parametrů.....	27
6.3 Jádrové odhady hustoty pravděpodobnosti.....	28
6.4 Korelační analýza	30
6.5 Klasifikační a regresní analýza	32
6.5.1 Klasifikační analýza	32
6.5.2 Regresní analýza	35
6.5.3 Testování pro všechna data.....	39
6.6 Sekvenční výběr parametrů	40
7 Závěr.....	46
Seznam použitých zdrojů.....	52
Seznam použitých zkratk a veličin	55
Seznam příloh	57

Seznam obrázků

Obr. 1.1: Závislost úbytku dopaminu na věku a typu průběhu PN [1].....	13
Obr. 6.1: Vyznačený „outlier“ pro jeden z parametrů.....	29
Obr. 6.2: Rozložení hustoty pravděpodobnosti pro počet špiček intonační funkce.	30
Obr. 6.3: Korelace klinických dat s novými parametry.....	31
Obr. 6.4: Korelace klinických dat s globálními parametry.....	32
Obr. 6.5: Průběh provádění změn selektorem u výběru parametrů pro klasifikaci.....	41
Obr. 6.6: Průběh změn u sekvenčního výběru parametrů pro UPDRS III.	42
Obr. 6.7: Průběh změn u sekvenčního výběru parametrů pro UPDRS IV.	43
Obr. 6.8: Průběh změn u sekvenčního výběru parametrů pro LED.	44
Obr. 6.9: Průběh změn u sekvenčního výběru parametrů pro DX.	45

Seznam tabulek

Tab. 1.1: Stádia Parkinsonovy nemoci [1].	15
Tab. 3.1: Dysartrický index [5].	18
Tab. 6.1: Databáze PARCZ.	27
Tab. 6.2: Klasifikační analýza pro vybrané parametry.	35
Tab. 6.3: Regresní analýza pro UPDRS III.	37
Tab. 6.4: Regresní analýza pro UPDRS IV.	38
Tab. 6.5: Regresní analýza pro LED.	38
Tab. 6.6: Regresní analýza pro DX.	39
Tab. 6.7: Klasifikační analýza pro všechna data.	39
Tab. 6.8: Regresní analýza pro všechna data.	40
Tab. 6.9: Výsledky sekvenční selekce parametrů pro klasifikační analýzu.	41
Tab. 6.10: Výsledky sekvenční selekce parametrů pro regresní analýzu UPDRS III.	42
Tab. 6.11: Výsledky sekvenční selekce parametrů pro regresní analýzu UPDRS IV.	43
Tab. 6.12: Výsledky sekvenční selekce parametrů pro regresní analýzu LED.	44
Tab. 6.13: Výsledky sekvenční selekce parametrů pro regresní analýzu DX.	45

Úvod

Parkinsonova nemoc (PN) je druhé nejčastější neurodegenerativní onemocnění. Projevuje se mimo jiné poruchami pohybu, nekontrolovaným třesem, poruchami řeči a psychickými problémy. Nemoc postihuje do velké míry každodenní život pacientů. Přesto se dodnes neví, co ji způsobuje. PN se nedá zcela vyléčit, dají se jen zmírnit její symptomy. Vývoj PN je pomalý a dlouholetý, bez viditelných projevů během prvních pár let. Včasné zahájení léčby je klíčové. Jelikož jsou jedním z prvních zpozorovatelných příznaků právě problémy s mluvou (porucha hypokinetická dysartrie), je důležité je správně a včas klasifikovat. Subjektivní analýza však velmi závisí na zkušenostech daného logopeda. Stále více se proto pro klasifikaci této dysartrické řeči využívá analýza řečových signálů. Jedná se o objektivní analýzu (řečové parametry jsou kvantifikovatelné jako čísla), která navíc může pomoci odhalit vady, které nejsou uchem slyšitelné [1], [2], [3], [4].

V rámci práce je nejdříve uvedena problematika PN – její historie, hypotézy vzniku, stádia a symptomy. Poté je popsána hypokinetická dysartrie a její symptom dysprozodie. Dále je vysvětlena metodika jak percepční, tak akustické analýzy dysartrie a je popsán test 3F. Následující kapitola se zabývá konvenčními parametry pro kvantifikaci dysprozodie. V páté kapitole jsou teoreticky popsány nové parametry pro výpočet dysprozodie, uvedené v této práci. Šestá kapitola pak popisuje celý praktický postup, popisuje použitou databázi PARCZ, použité skripty, výpočet nových parametrů, výpočet hustoty pravděpodobnosti, korelační analýzu, klasifikační a regresní analýzu s novými parametry včetně stručné teorie použitých klasifikátorů a vypočtených metrik, a nakonec sekvenční výběr těchto parametrů. Tato kapitola pak především obsahuje formou grafů a tabulek výsledky práce. Ty jsou pak, společně s dalšími poznatky, shrnuty v závěru.

1 Parkinsonova nemoc

Parkinsonova nemoc (resp. Parkinsonské syndromy, jak se obecně říká sboru symptomů PN) je způsobena degenerací pigmentových buněk pars compacta v substantia nigra ve středním mozku a následným nedostatkem dopaminu v této oblasti. Pravá příčina či příčiny vzniku nemoci ale nejsou dosud známy [1].

1.1 Historie


Nemoc byla poprvé popsána roku 1817 anglickým lékařem Jamesem Parkinsonem v knize *An Essay on the Shaking Palsy*. Autor zde popisuje 6 případů onemocnění, projevujícího se třesem, poruchami stání a pohybu. Brzy na to pánové Charcot a Gowers doplnili symptomy o rigiditu a pojmenovali nemoc po jejím objeviteli. Popisy nemocí s nápadně podobnými symptomy se objevují již mnohem dříve, ale nelze dokázat, zda se opravdu jednalo o PN, ani v jakém rozsahu se vyskytovala. V návaznosti na tyto poznatky již v roce 1867 Charcot a Ordenstein začali úspěšně léčit PN rostlinným přípravkem beladonou (léčením zde myslíme pouze tišení symptomů, nebo zpomalení degenerace buněk, samotná nemoc je ještě v dnešní době bohužel nevyléčitelná). Roku 1913 doktor Lewy objevil v mozcích pacientů zemřelých na PN mikroskopická tělíska, která po něm byla pojmenována jako Lewyho tělíska, a roku 1919 popsal Tretjakov u zesnulých pacientů poškození substantia nigra. V roce 1958 zjistil Carlsson, že se dopamin vyskytuje ve velkém množství v bazálních gangliích, a díky tomu roku 1960 Ehringer a Hornykiewicz prokázali, že je PN způsobena nedostatkem dopaminu v substantia nigra. Roku 1961 se k léčbě PN začal používat L-DOPA (prekurzor dopaminu). Od r. 1967 se začal používat společně s inhibitorem enzymu dekarboxylázy, což odstranilo většinu vedlejších účinků léčby, a tato kombinace je do dnešní doby nejúčinnějším lékem na PN (L-DOPA má však negativní účinky na pozdější stádia nemoci při dlouhodobém užívání). Dalším důležitým objevem byl objev látky zvané MPTP Langstonem v r. 1983. Tato látka vzniká jako vedlejší produkt při nesprávné výrobě heroínu. MPTP má selektivní neurotoxický efekt na dopaminergních buňkách a u otrávených pacientů se vyvíjejí příznaky k nerozpoznání od symptomů PN. Navíc zabírají na otravu MPTP stejné léky jako na PN. Tento objev poukázal na jednu z možných příčin nemoci – exotoxickou hypotézu. V následujících letech, a i do dnešní doby, pokračuje výzkum za účelem zjištění, co je pravou příčinou vzniku PN, objevování nových způsobů léčby a hledání ukazatelů nemoci, detekovatelných již v preklinickém stádiu nemoci, jelikož právě včasný objev a zahájení léčby nemoci jsou klíčové.

1.2 Vznik Parkinsonovy nemoci

Jak již bylo řečeno výše, PN způsobuje odumírání dopaminergních buněk a následný nedostatek dopaminu. Dopamin je hormon, který funguje jako neuromediátor – umožňuje přenos nervových vzruchů, především těch, co řídí pohyb. Dalším účelem dopaminu je částečné řízení emocí, hlavně pozitivních, a pozitivní odezvy na vnější podněty. Toto souvisí s dalším běžně se vyskytujícím symptomem PN – depresí. Dopamin vzniká dekarboxylací L-DOPA účinkem dekarboxylázy aromatických aminokyselin.

Není známo, co způsobuje odumírání dopaminergních buněk. Bylo zjištěno, že samotné příznaky nemoci se objevují až po delším preklinickém období, trvajícím cca 3–5 let. Během této fáze dochází ke zvýšené produkci dopaminu zbývajícími dopaminergními buňkami, což vede až k hypersenzitivitě organismu na dopamin. Teprve až když po několika letech preklinického vývoje nemoci dojde k poklesu dopaminu pod 20 %, začínají se objevovat první symptomy. Také proces stárnutí s sebou přináší pokles dopaminu, cca 5–8 % na dekádu. Existují 4 hypotetické typy rozvoje poklesu dopaminu:

- A. Nedostatek dopaminu v substantia nigra je přítomen již od narození a přirozeným procesem fyziologického stárnutí dojde k jeho poklesu pod kritickou úroveň.
- B. Vlivem vnějšího či vnitřního prostředí dojde k jednorázovému poškození dopaminergních buněk, nebo schopnosti syntézy dopaminu a dále vlivem stárnutí dojde k poklesu pod kritickou hranici.
- C. Již od počátku života se rozvíjí akcelerovaná ztráta syntézy dopaminu, nebo akcelerovaná buněčná smrt.
- D. Zrychlená ztráta syntézy dopaminu, či zrychlená buněčná smrt se spustí vlivem vnějšího či vnitřního prostředí až někdy během středního věku života (Obr. 1.1).



Obr. 1.1: Závislost úbytku dopaminu na věku a typu průběhu PN [1].

Existují 3 základní hypotézy vzniku PN. Endotoxická hypotéza, exotoxická hypotéza (rozvoje B a D) a hypotéza genetické poruchy (rozvoj A a C), viz Obr. 1.1. Je pravděpodobné, že jednotlivé hypotézy od sebe nelze oddělit, jedna podmiňuje druhou a PN je způsobena všemi společně, nebo že může být způsobena každou jednou z nich (nebo i nějakou dosud neobjevenou) a nezávisle na sobě mohou různé okolnosti vzniku vézt ke stejné nemoci.

- **Endotoxická hypotéza** – ve všech částech mozku se běžně vytvářejí škodlivé látky – endotoxiny. Tělo má za normálních podmínek dostatečné detoxikační mechanismy, aby se mohlo takovýmto látkám bránit. V mozku pacientů s PN dochází k přebytku volných radikálů kyslíku, což způsobuje buněčnou smrt. Není však známo, jestli se jedná o primární příčinu nemoci, nebo jen o jeden z důsledků degenerace neuronů. Také vyvstává otázka, či jde o nadprodukcí volných radikálů kyslíku (např. u abnormálního metabolismu železa či dopaminu, u genetické poruchy, nebo otravy exotoxinem) nebo o poškození detoxikačních mechanismů (např. u genetické poruchy, nebo u otravy exotoxinem).
- **Exotoxická hypotéza** – opírá se především o objev MPTP (viz kap. Historie). MPTP samo o sobě toxické není, ale při průchodu mozkem konvertuje na nestabilní MPP+, které postupně způsobuje neuronální smrt (navíc dochází k nadměrné generaci volných radikálů kyslíku). I přes velkou podobnost PN a intoxikace MPTP však studie prokázaly drobné odlišnosti, navíc nelze vysvětlit, proč pouze někteří otrávení pacienti onemocní PN a jiní ne.
- **Genetická hypotéza** – Asi 5 % pacientů s PN udává, že byl někdo z příbuzných podobně postižen. Tento fenomén se ale vyskytuje téměř výlučně jen u osob postižených před 21. narozeninami (tzv. juvenilní typ PN – hypotéza C), viz Obr. 1.1. Zde ale opět nelze říci, jestli se jedná opravdu o genetickou mutaci, nebo je PN způsobena např. výskytem určitého exotoxinu na místě, kde rodina žije. Někteří autoři se dokonce domnívají, že juvenilní typ PN je ve skutečnosti úplně jiná nemoc, či dokonce několik různých onemocnění.

Správná klasifikace, že se opravdu jedná o PN, je důležitá, jelikož Parkinsonské syndromy jsou jen v 70–80 % případů zapříčiněny touto nemocí, u ostatních případů jde o jiná onemocnění centrálního nervového systému poškozující extrapyramidové struktury. Některá z nich mají rovněž progresivně degenerativní charakter a od PN se liší pouze drobnými změnami, což dále ztěžuje diagnostiku PN (např.: Alzheimerova nemoc, Hallervordenova–Spatzova nemoc, polékový syndrom, posttraumatický syndrom, multisystémová atrofie a další).

1.3 Stádia a symptomy Parkinsonovy nemoci

Průběh a trvání jednotlivých stádií se liší podle jednotlivce. Typ nemoci, rozsah poškození i úspěšnost léčby jsou všechno ovlivňující faktory. PN lze ale rozdělit na několik vždy přesně po sobě následujících stádií podle popisu Hoehnové a Yahra z roku 1967.

Tab. 1.1: Stádia Parkinsonovy nemoci [1].

Stádium	Příznaky
Stádium 0	Preklinické období, bez příznaků
Stádium 1	Jednostranné příznaky
Stádium 1,5	Jednostranné a axiální postižení
Stádium 2	Oboustranné postižení bez poruchy rovnováhy
Stádium 2,5	Oboustranné postižení s mírnou poruchou rovnováhy
Stádium 3	Středně těžké oboustranné postižení, porucha rovnováhy
Stádium 4	Těžké postižení, pacient schopen chodit nebo stát bez pomoci
Stádium 5	Pacient odkázán na vozík nebo lůžko, nedokáže vstát bez pomoci

1.3.1 Příznaky v prvních stádiích nemoci

Tremor (třes) – jedná se o mimovolný periodický pohyb končetin o kmitočtu 4–6 Hz, u PN nejčastěji jako klidový třes, který se projevuje, pouze pokud pacient končetinou právě nehýbe. Rigidita (svalová ztuhlost), bradykineze (zpomalení pohybů), hypokineze (zmenšení rozsahu pohybů) a akineze (neschopnost pohyb vykonat), drobné poruchy stání a chůze, poruchy pohybů očí a víček, mentální dysfunkce, **hypokinetická dysartrie** (porucha řeči) a mikrografie (porucha čitelnosti psaného projevu). Právě poslední dvě, společně s bolestí ramen a zad, pocitem tíže končetin, únavou, ztrátou výkonnosti a potence, zácpou, poruchami spánku a depresí (zde uvedené mohou být všechny dány jinou nemocí, nebo samotným stárnutím) jsou jedněmi z vůbec prvních pozorovatelných příznaků PN. Vzhledem k důležitosti včasné klasifikace PN je důležité dále rozvíjet výzkum právě těchto dvou příznaků.

1.3.2 Příznaky v pokročilých stádiích nemoci

Pozdní fáze se kromě zhoršení již probíhajících příznaků projevují především kolísáním stavu hybnosti v závislosti na léčbě L-DOPA. Rozdíly mezi dobou bezprostředně po aplikaci léčebné dávky a dobou bez ní se zvětšují, postupně může být pacient před dostáním další dávky léků až o několik stádií horší. Navíc se stav nadále komplikuje právě také léčbou samotnou. V této fázi se objevují také dyskineze (mimovolné pohyby), zhoršuje se chůze a objevují se pády, objevují se závažné vegetativní poruchy (předkolapsové stavy až kolapsy, poruchy močení, zácpa, poruchy polykání, vytékání slin z úst, nechutenství, nadměrné pocení, horečka, nebo naopak zimnice a poruchy citlivosti) a noční problémy (hlavně insomnie, noční můry a akutní stavy úzkosti, horší hypokinetické projevy během noci – neschopnost obrátit se, nebo vstát a prohloubení deprese).

2 Hypokinetická dysartrie

Dysartrie je neurogenně podmíněná narušená komunikační schopnost – porucha svalové kontroly řečového mechanismu [2]. Dysartrie je vždy definována jako vícekomponentová porucha řeči způsobená poškozením nervové soustavy při neurologickém onemocnění. Vícekomponentovost znamená, že dysartrie narušuje v různé míře více komponentů, nebo všechny komponenty, které se podílí na realizaci řeči, tj. především: respirace, fonace, rezonance, artikulace a prozodie. V dnešní době se dysartrie rozděluje na sedm základních typů podle sluchově–percepčních charakteristik řeči nemocných pacientů. Dysartrie doprovázející PN se nazývá hypokinetická (HD).

HD vzniká při lézích bazálních ganglií a jejich okruhů. Trpí jí až 90 % pacientů s PN [3]. Ta je její nejčastější příčinou, ale může být způsobena i úrazy hlavy. Nejvíce postiženými komponenty tvorby řeči jsou: artikulace, fonace, prozodie, plynulost projevu, dýchání a faciokineze. Zde je nutno podotknout, že příznaky poruchy a jejich rozsah se pro každého pacienta mohou lišit. Nejfrekventovanějšími příznaky jsou **dysprozodie**, tichá řeč (hypofonie), zrychlená artikulace, palilálie (rychlé opakování slov a slabik) a snížená intenzita hlasu. Vypozorována byla také zvýšená dušnost, zvýšený akustický šum hlasu, zvýšení nosovosti řeči, špatná výslovnost souhlásek, nedobrovolné pauzování řeči a náhlé zrychlování a zpomalování řeči.

2.1 Dysprozodie

Lidské řeč vzniká koordinovaným pohybem více jak stovky svalů. Prozodie je důležitou součástí lidské řeči. Její znaky odrážejí sémantické, syntaktické a emoční informace řečníka [4]. Mezi znaky prozodie se řadí rychlost a rytmus řeči a také dynamický a tónový rozsah mluveného projevu. V důsledku ztuhlosti svalů vokálního traktu u hypokinetické dysartrie dochází i k poškození těchto znaků. Hlavními projevy dysprozodie jsou:

- **Monotónnost řeči bez intonace** (nedostatečné kolísání základního tónu řeči).
- **Nedostatečná variabilita intenzity řeči** (především tichá, nesrozumitelná řeč).
- **Chyby rytmu a rychlosti projevu** (nepřirozené pauzování, zrychlování, zpomalování).

3 Analýza řeči pacientů s dysartrií

Pokud lékař stanoví, že jsou řečové problémy pacienta způsobeny dysartrií, následuje logopedické vyšetření, kde se logoped snaží detailně zmapovat poškození všech komponent tvorby řeči (kap. 2) a na jejich základě určit typ dysartrie a kvantifikovat stupeň poruchy. K tomu může v praxi použít dva přístupy:

- **Percepční hodnocení:** jedná se stále o nejpoužívanější metodu, kdy logoped provede subjektivní analýzu srozumitelnosti řeči, přesnosti artikulace a zhodnocení různých dimenzí řeči [2]. Tato metoda má však nevýhodu, že výsledky mohou být ovlivněny subjektivním postojem daného logopeda.
- **Akustické hodnocení:** opírá se o objektivní akustickou analýzu nahrávky řeči pacienta. Jednotlivé příznaky řeči se pak dají kvantifikovat jako akustické parametry (např.: chraptění jako úroveň šumu nahrávky, monotónnost řeči jako nedostatečné kolísání základního kmitočtu f_0 atd.). Oproti percepčnímu hodnocení má akustické několik výhod, kromě již zmíněné kvantifikace je to především odstranění lidské chyby u subjektivního hodnocení (pokud programátor neprovede chybu při implementaci algoritmu). Další výhodou je získání mnohem větší škály hodnocení vážnosti příznaků (většina subjektivních testů používá třístupňovou až pětistupňovou škálu hodnocení, rozdělení do více stupňů by bylo pro logopeda velmi obtížné) a rychlé a levné získání velkého množství parametrů i statistických veličin. Je ale třeba brát v potaz, že výsledky akustického hodnocení jsou velmi závislé na správné implementaci metod analýzy signálů a také na kvalitě nahrávacího zařízení, kterým byla nahrávka pořízena.

V současné době se stále více začíná používat kombinovaná metoda, kdy logoped provede standardní percepční hodnocení, které doplní o akustické výsledky a vyhodnocení provede na základě obojího.

3.1 Test 3F

V Čechách je pro diagnostiku dysartrie dostupných několik metodik. Nejčastěji je používán test 3F [5]. Test neslouží k určení typu dysartrie, pouze ke zhodnocení závažnosti nemoci. Je rozdělen na dvě základní části, a to orientační předtestové vyšetření a samotný test. Výsledky z předtestového vyšetření se nezapočítávají do celkových výsledků, ale upozorní nás na přítomnost některých poruch (např.: apraxie, dyslalie), které by mohly ovlivnit výsledek samotného testu. Test se pak skládá ze tří funkčních celků: F1 – faciokineze, F2 – fotorespirace a F3 – fonetika. Každá podskupina testu má pak tři samostatné části po pěti úkolech. Jednotlivé úkony jsou obodovány následovně:

- **2 body** za správně provedený úkol
- **1 bod** za lehké až středně těžké potíže s provedením úkolu
- **0 bodů**, pokud pacient neprovedl úkol vůbec nebo jen náznakem.

Dále je možnost udělení mezistupně, pokud se logoped nemůže rozhodnout například mezi udělením jednoho a nula bodů. Celková škála hodnocení je tedy pětistupňová.

Výsledky testu se následně sečtou a získá se dysartrický index a dysartrický profil. Maximální počet bodů z testu je 90. Dysartrický index (DX) vyjadřuje míru poruchy podle dosaženého počtu bodů, dysartrický profil je pak vykreslení bodů získaných v jednotlivých subkapitolách do jednoho grafu. Hodnocení je nastaveno následovně, viz Tab. 3.1.

Tab. 3.1: Dysartrický index [5].

Dosažený počet bodů	Diagnóza
85–90 b.	Bez poruchy
74–85 b.	Velmi lehká dysartrie (nebo jen prosté snížení motorických dovedností bez patologické příčiny)
57–73 b.	Lehká dysartrie
36–56 b.	Středně těžká dysartrie
17–35 b.	Těžká dysartrie
0–17 b.	Velmi těžká dysartrie (anartrie)

Test 3F využívá úkoly přizpůsobené povaze českého jazyka. Jedná se o percepční test, který může být doplněn o zpracování řečových signálů. Byl již několikrát upraven a cílem autorů je dále jej vylepšovat a následně standardizovat.

4 Konvenční parametry kvantifikující dysprozodii

Dysprozodie se vyznačuje především nedostatečnou melodičností hlasu, nesprávnou rytmiizací a špatným tempem řeči. Nedostatečnou melodičností myslíme nedostatečné kolísání výšky a intenzity hlasu, chybami v rytmu především nesprávné vkládání pauz, chybami v tempu pak nesprávné zpomalování a zrychlování řeči [4]. Všechny tyto vady mohou být kvantifikovány jako akustické parametry. Takovým parametrem může být skalár, vektor, či matice čísel a lze jej počítat z celého řečového signálu, nebo z krátkých úseků, ve kterých považujeme signál za stacionární [2], [6]. Zde bude popsáno, jaké jsou nejčastěji používané metody pro zpracování těchto vad.

- **Výška hlasu** – nedostatečné kolísání výšky hlasu můžeme kvantifikovat jako nedostatečné kolísání fundamentálního kmitočtu f_0 . Tento parametr je vhodné počítat z delších úseků řeči, kde jsme si jisti, že hlasivky opravdu kmitají. Pro výpočet kolísání f_0 u dysprozodie se používají především statistické veličiny, jako je směrodatná odchylka, rozsah a další, viz kap. 6.2.
- **Intenzita hlasu** – k popisu kolísání intenzity v čase se pro dysprozodii nejčastěji používá střední krátkodobá energie signálu (kap. 5), dále se dá použít Teagerův–Kaiserův operátor, či medián spektrální výkonové hustoty a opět jejich statistické veličiny.
- **Rytmus a tempo řeči** – k výpočtům souvisejícím s tempem řeči se používají 3 základní parametry, a to: **TST** (Total Speech Time) – trvání celého řečového signálu, **TPT** (Total Pause Time) – trvání všech pauz delších než 10 ms a **NST** (Net Speech Time) – trvání čistě řečového signálu (s) v celkovém signálu, který se vypočítá jako:

$$NST = TST - TPT. \quad (4.1)$$

Z těchto parametrů můžeme dále vypočítat tempo řeči, potřebujeme k tomu znát ještě **PS** – celkový počet slabik řečového signálu. **TSR** (Total Speech Rate) – absolutní tempo (slabiky/s):

$$TSR = \frac{PS}{TST}. \quad (4.2)$$

NSR (Net Speech Rate) – tempo čistě řečového signálu (slabiky/s):

$$NSR = \frac{PS}{NST}. \quad (4.3)$$

Tyto parametry můžeme dále použít pro výpočet pauzování řeči. Vyjadřujeme především: **PPR** (Percentual Pause Ratio) – procentuální poměr pauz (%):

$$PPR = \frac{TPT}{TST} \quad (4.4)$$

a **RIWP** (Ratio of Intra-Word Pauses) – procentuální poměr pauz uvnitř slov (%):

$$RIWP = \frac{TIPT}{TPT}, \quad (4.5)$$

kde **TIPT** (Total Intra-Word Pause Time) udává celkovou délku pauz uvnitř víceslabičných slov.

VOT (Voice Onset Time) – definován jako doba mezi prvním zákmitem plosivy a začátkem vokálu. Liší se podle dané vyslovované hlásky (25–100 ms u zdravého jedince), u patologické řeči je tato doba delší [2].

AR (Articulation Rate) – tempo udávající počet slabik za celkové trvání všech pauz delších, než 50 ms (**TPT₅₀**). Udává se v slabikách/s [7]:

$$AR = \frac{PS}{TPT_{50}}. \quad (4.6)$$

SPIR (Speech Index of Rhythmicity) – udává počet pauz delších než 50 ms za minutu (počet pauz/minutu):

$$SPIR = \frac{TPT_{50}}{60}. \quad (4.7)$$

5 Nové parametry kvantifikující dysprozodii

Tato práce testuje, kromě konvenčních parametrů pro výpočet nedostatečného kolísání základní frekvence, nedostatečného kolísání intenzity signálu a časových veličin popsaných nahoře, především řadu nových intonačních, časových a globálních parametrů pro výpočet dysprozodie.

5.1 Nové intonační parametry

V této práci se testuje 5 nových parametrů pro kvantifikaci intonace řeči (jedná se především o mutace parametrů konvenčních a poslední je kombinací frekvence a energie do jednoho parametru). První 2 – parametry pro nedostatečné kolísání výšky (*monokmitočet*) a energie (a tedy intenzity – *monohlasitost*) signálu – využívají kumulativního součtu absolutních diferencí f_0 , resp. krátkodobé energie, podělené tímto kmitočtem, resp. energií. Dále se zde testuje *variabilita výšky* a *variabilita energie* signálu, které jsou definovány jako série absolutních diferencí mezi po sobě následujícími hodnotami f_0 , resp. energie, trimované (zredukované) mediánem těchto absolutních diferencí. Pátým parametrem je pak *intonace řeči*, která popisuje změny kmitočtu a intenzity zároveň.

- **Variabilita kmitočtu signálu** – vstupem do této funkce je vektor již vypočtených hodnot f_0 , vzorkovací kmitočet ze vstupního signálu a nastavení, jestli chceme přepočítat signál na semitónovou stupnici. Zde je použita pro výpočet f_0 volně dostupná funkce Praat z Amsterdamské Univerzity. Variabilita kmitočtu signálu pak nejdříve odstraní všechny nulové hodnoty ze vstupních dat. Následně, podle zadání, přepočítá, nebo nepřepočítá vektor hodnot f_0 na půltónovou stupnici, podle vzorce pro n -tý prvek vstupního vektoru:

$$f_{0_{semitone}}(n) = 12 * \log_2 \left(\frac{f_0(n)}{f_0(n-1)} \right). \quad (5.1)$$

Poté jsou vypočteny absolutní difference těchto hodnot. Pro n -tý prvek vstupního vektoru hodnot f_0 se absolutní difference rovná:

$$Absdiff(n) = |f_0(n) - f_0(n-1)|. \quad (5.2)$$

Dále je tento vektor absolutních diferencí zredukován odstraněním všech nedůležitých hodnot. Skript odstraní všechny hodnoty absolutních diferencí, které jsou menší než medián těchto hodnot. Nakonec funkce vrací výstupní parametry. Kromě již zmíněných zredukováných absolutních diferencí, funkce počítá také počet špiček v signále (počet hodnot ve vektoru zredukováných absolutních diferencí, které jsou větší, než 2 sousední hodnoty) a strmostní funkce kumulativního součtu těchto hodnot. **Čím větší hodnoty, větší počet špiček**

a strmější funkce, tím více kolísal základní kmitočet signálu a tím pádem je řeč méně dysprozodická.

- **Variabilita energie signálu** – tato funkce je velmi podobná, jako předchozí. Vstupem do funkce je vektor již vypočtených hodnot krátkodobé energie vstupního signálu, vzorkovací kmitočet a informace, jestli chceme přepočítat amplitudu signálu na decibely. Zde je pro výpočet energie použita funkce `energy.m`, která nejdříve vstupní signály nasegmentuje podle zadání (zde bylo použito Hammingovo okno o délce 20 ms s překryvem 50 %) a vypočítá krátkodobou energii diskrétního signálu podle vzorce:

$$E = \sum_{n=0}^{N-1} |x[n]|^2, \quad (5.3)$$

kde $x[n]$ je úsek, ze kterého se tato energie počítá a N je celkový počet úseků.

Poté jsou z vektoru energií odstraněny nulové hodnoty, případně je vektor přepočítán na decibely, a jsou opět vypočteny hodnoty absolutních diferencí trimované mediánem těchto hodnot. Výstupem je opět série variability energie, počet špiček a strmostní funkce kumulativního součtu těchto hodnot. Čím větší hodnoty variability energie, vyšší počet špiček a strmější funkce, tím více kolísala hlasitost mluvy a řeč je méně dysprozodická.

- **Monokmitočet** – vstupem do této funkce je neupravený vstupní signál, vzorkovací kmitočet tohoto signálu a kmitočtové meze f_{min} a f_{max} , v jejichž rámci provádí funkce Praat analýzu. Meze byly nastaveny na 75 a 400 Hz, jelikož toto rozmezí by mělo pokrýt rozsah základních frekvencí od nejnižšího pánského hlasu po nejvyšší ženský soprán. Skript nejdříve provede segmentaci signálu podle nastavených parametrů (zde použito Hammingovo okno délky jedné sekundy, s překryvem 50 %). Poté funkce používá opět program Praat pro výpočet základního kmitočtu hlasového traktu z těchto segmentů. Následně z vektoru těchto frekvencí odstraní všechny nulové hodnoty, nečíselné hodnoty, všechna nekonečna a všechny hodnoty f_0 kratší než 3 vzorky. Pak funkce přepočítá stupnici na půltónovou podle vzorce (5.1). Dále je vypočten kumulativní součet absolutních hodnot diferencí vektoru fundamentálních frekvencí, normalizovaný počtem těchto hodnot a podílem směrodatné odchylky k průměru hodnot vektoru hodnot f_0 . Hodnota n -tého prvku tohoto vektoru se vypočítá jako:

$$CSADf_0(n) = \left(\frac{\sqrt{\frac{1}{N-1} * \sum_{i=1}^N |f_0 - \mu|^2}}{\mu} \right) * \left(\frac{\sum_{m=1}^N |f_0(n) - f_0(n-1)|}{\left| \vec{f_0} \right|} \right), \quad (5.4)$$

kde f_0 je vektor základních frekvencí, N je počet prvků ve vektoru f_0 , $\left| \vec{f_0} \right|$ je délka tohoto vektoru a μ je průměr vektoru f_0 , podle vzorce:

$$\mu = \frac{1}{N} * \sum_{i=1}^N f_0. \quad (5.5)$$

$CSADf_0$ je takto normalizován, aby zůstaly jen hodnoty od 0 do 1 a jednotliví řečníci byli mezi sebou dobře porovnatelní. Poté funkce ještě odstraní z vektoru výstupních hodnot $CSADf_0$ všechny prázdné hodnoty a výstupem je pak opět tento vektor a strmostní funkce kumulativního součtu hodnot tohoto vektoru. Opět platí, že čím vyšší hodnoty a strmější funkce, tím je řeč méně dysprozodická.

- **Monohlasitost** – postup u výpočtu této funkce je stejný jako u funkce předchozí, jen se místo základního kmitočtu vypočítává krátkodobá energie signálu, viz vzorec 5.3 (je zde použita stejná funkce `energy`, jako u variability energie signálu), a následný kumulativní součet absolutních diferencí se počítá z této krátkodobé energie pro n -tý prvek vektoru jako:

$$CSADE(n) = \left(\frac{\sqrt{\frac{1}{N-1} * \sum_{i=1}^N |E - \mu|^2}}{\mu} \right) * \left(\frac{\sum_{m=1}^N |E(n) - E(n-1)|}{\left| \vec{E} \right|} \right), \quad (5.6)$$

kde E je vektor základních frekvencí, N je počet prvků ve vektoru E , $\left| \vec{E} \right|$ je délka tohoto vektoru a μ je aritmetický průměr vektoru E (podle vzorce 5.5).

Výstupem je opět vektor $CSADE$ a jeho strmostní funkce. Platí, že čím vyšší hodnoty (bližší hodnotě 1) a strmější funkce, tím více kolísala hlasitost mluvy.

- **Intonace řeči** – tato funkce je kombinací funkcí předchozích. Vstupem je řečový signál, vzorkovací kmitočet, parametry pro segmentaci a frekvenční meze pro extrakci základních kmitočtů. Na začátku proběhne segmentace podle zadaných parametrů (zde použito Hammingovo okno délky jedné sekundy s překryvem 50 %). Následně jsou vypočteny jak základní kmitočet (nastavení opět v mezích 75 a 400 Hz), tak krátkodobá energie segmentů. Výsledné hodnoty kmitočtu a energie jsou pak vypočteny jako medián těchto hodnot, podělený maximální hodnotou na každý segment. Poté jsou opět odstraněny všechny nulové hodnoty, nečíselné hodnoty, všechna nekonečna a všechny hodnoty f_0 kratší než 3 vzorky. Z těchto je pak dohromady vypočtena intonační funkce podle vzorce pro n -tý prvek vektoru intonační funkce:

$$IR(n) = \frac{|f_0(n) - f_0(n-1)| * |E(n) - E(n-1)|}{\sum_{i=1}^N v}, \quad (5.7)$$

kde f_0 je vektor základních kmitočtů, E je vektor s hodnotami krátkodobých energií, N je počet prvků ve vektoru *Intonace* a v je vektor pozic, na kterých jsou zároveň vektor f_0 a E číselné hodnoty, kterým se tato funkce normalizuje.

Výstupem je pak tato intonační funkce, počet špiček zjištěný pomocí funkce `findpeaks` a strmestní funkce kumulativního součtu této intonační funkce. Opět platí, že čím vyšší hodnoty intonačního parametru, větší počet špiček a strmější funkce, tím více kolísala celková intonace řeči a řeč je méně dysprozodická. Jelikož se u této intonační funkce sledují dva parametry (kmitočet i energie) naráz, měla by tato funkce být obzvláště účinná, pokud vyjdou oba parametry nízké (řeč je dysprozodická), nebo naopak oba vysoké (řeč by měla být v pořádku).

5.2 Nové časové parametry

Pro dosažení cíle vytvoření jednoho globálního parametru pro celou dysprozodii bylo dále třeba zkombinovat parametry popisující rytmus a tempo dohromady. Tato práce uvádí a testuje 3 nové parametry, které jsou poměry konvenčních rytmických a tempových parametrů (kap. 4).

- **Total-to-net speech rate** – poměr absolutního tempa a tempa čistě řečového signálu. Nejedná se tedy o globální časový parametr, ale pouze o další tempový parametr. Výpočet:

$$TNSR = \frac{TSR}{NSR}. \quad (5.8)$$

- **Tempovost** – poměr net speech rate (*NSR*) a articulation rate (*AR*). Zde se jedná již o globální časový parametr, protože i když má articulation rate v názvu tempo, jedná se spíše o rytmický parametr [7]. *NSR* byl vybrán za čítel, protože *AR* také nepočítá s žádnými pauzami, tempovost je tedy globální časový parametr bez *TPT* (total pause time). Výpočet:

$$Tempovost = \frac{NSR}{AR}. \quad (5.9)$$

- **Universal speech rate constant** – poměr absolutního tempa (*TSR*) a řečového indexu rytmicity (*SPIR*). Opět tedy obsahuje rytmus i tempo, tentokrát ale počítá i s pauzami.

$$USRC = \frac{TSR}{SPIR}. \quad (5.10)$$

5.3 Globální parametry

Globálních parametrů pro popis dysprozodie je v této práci uvedeno celkem 5 a jedná se vždy o poměr Intonace řeči k novým nebo konvenčním rytmickým parametrům. Za číslo popisující parametr Intonace řeči byla vybrána derivace křivky strmostní funkce, jelikož měla při korelační analýze nejlepší výsledky ze všech statistických veličin Intonace řeči. Označení parametru je vždy GP (globální parametr) a index popisující jmenovatel.

- **GP_{USRC}** – poměr intonace řeči a universal speech rate constant.

$$GP_{USRC} = \frac{IR}{USRC}. \quad (5.11)$$

- **$GP_{Tempovost}$** – poměr intonace řeči a parametru *Tempovost*.

$$GP_{Tempovost} = \frac{IR}{Tempovost}. \quad (5.12)$$

Tento a předchozí parametr jsou tedy globální parametry obsahující všechny čtyři složky dysprozodie. Dále jsou v této práci testovány ještě 3 další „globální“ parametry, které kombinují intonaci alespoň s rytmem nebo celkovým časem, a to:

- **GP_{TNSR}** – poměr intonace řeči a Total-to-net speech rate.

$$GP_{TNSR} = \frac{IR}{TNSR}. \quad (5.13)$$

GP_{TSR} – poměr intonace řeči a absolutního tempa. Popisuje závislost intonačních změn na tempu řeči.

$$GP_{TSR} = \frac{IR}{TSR}. \quad (5.14)$$

- **GP_{TST}** – poměr intonace řeči k celkovému času nahrávky.

$$GP_{TST} = \frac{IR}{TST}. \quad (5.15)$$

Tento poslední parametr není bezrozměrný, ale je udán v s^{-1} , dal by se tedy popsat jako frekvence intonačních změn za dobu celého signálu.

6 Výsledky

Celá praktická část této diplomové práce byla zpracována v prostředí Matlab R2018a (verze 9.4). Hlavním cílem praktické části bylo otestování nových parametrů k popisu dysprozodie, popsaných v kapitole č. 5. Tyto parametry byly testovány na databázi PARCZ.

6.1 Databáze PARCZ

Neboli Czech Parkinsonian Speech Database je databáze v českém jazyce obsahující nahrávky jak zdravých osob, tak osob postižených PN. Jedná se o nahrávky subjektů během plnění testu 3F. Byla vytvořena ve spolupráci Fakultní nemocnice u sv. Anny v Brně a I. Neurologické kliniky Lékařské fakulty Masarykovy univerzity. Záznam byl pořízen kondenzátorovým mikrofonom M-AUDIO NOVA přibližně 20 cm od úst řečníka v tiché místnosti (SNR větší, než 30 dB) s částečnými bezodrazovými akustickými prvky [8]. Pro účely testování v této práci byla z databáze použita řečová úloha č. 8.1: Udržení rytmu v rytmickém celku. Úloha spočívá ve čtení následující básně:

*Chcete vidět velký lov?
Budu lovit v džungli slov.
Osedlám si Pegasa,
chytím báseň do lasa.*

Tato úloha je pro toto testování dostatečná, protože obsahuje všechny aspekty prozodie řeči. Při přednášení básně se dostatečně projevují intonační parametry a zde je navíc po pacientech vyžadováno, aby báseň četli v konstantním tempu a rytmu.

Poskytnutá databáze obsahovala nahrávky ve formátu .wav se vzorkovacím kmitočtem $f_{vz} = 16$ kHz a .xlsx soubor s metadaty obsahující číselné označení jednotlivých řečníků (vypovídající o zdraví/nemoci dané osoby a jejich pohlaví), jejich věk, dysartrický index těchto osob a pro osoby nemocné také UPDRS III, UPDRS IV a LED.

- **UPDRS III** – (Unified Parkinson's Disease Rating Scale, part 3 – unifikovaná škála pro hodnocení Parkinsonovy nemoci, 3. část), jedná se o test motorických dovedností, více bodů se získá při vážnějších projevech symptomů.
- **UPDRS IV** – 4. část UPDRS testující komplikace spojené s léčbou, opět je více bodů za horší projevy [9].
- **LED** – popisuje denní dávku L-DOPA v mg/den.

Po odstranění nesrovnalostí mezi nahrávkami a .xlsx souborem (některé nahrávky básní chyběly) a odstranění dvou pacientů, pro něž sice byly dostupné nahrávky, ale v tabulce nebyly žádné informace, zůstala databáze následující velikosti (Tab. 6.1).

Tab. 6.1: Databáze PARCZ.

	Zdravé ženy	Zdraví muži	Nemocné ženy	Nemocní muži
Počet	26	26	38	59
Rozpětí věku	45–87	49–83	49–86	46–86
Věkový průměr	62,15	65,58	68,76	66,36
Průměr UPDRS III	–	–	22,03	26,76
Průměr UPDRS IV	–	–	2,92	3,36
Průměr LED	–	–	806,86	1110,45
Průměr DX	–	–	72,45	75,22

6.2 Výpočet nových parametrů

Nejdříve byl vytvořen skript `DP_vypocet_vsech_parametru.m`, s jehož pomocí byly vypočteny tradiční parametry, viz kap. 4 – konkrétně statistické veličiny základního kmitočtu, krátkodobé energie, Teagerova–Keiserova operátoru, rytmické veličiny a nové parametry popsané v kap. 5. Jelikož se ale u nových intonačních parametrů jednalo o velké množství dat (výsledné vektory měly desítky, až stovky hodnot, v závislosti na délce nahrávky a použitého okna), byly na vektory aplikovány statistické veličiny. Použitím statistiky na skupinu čísel se získá číslo jedno, v této práci bylo použito 5 statistických veličin, což snížilo počet čísel na 5 pro každý intonační parametr. Byl vytvořen skript `statistika.m` a pomocí něj vypočteny tyto statistické veličiny:

- **Směrodatná odchylka** – udává, jak jsou hodnoty rozloženy kolem průměru. Vypočítá se jako odmocnina z variance:

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |f_{0i} - \mu|^2}, \quad (6.1)$$

kde f_{0i} je vektor vstupních hodnot, N je počet prvků v něm a μ je aritmetický průměr z těchto hodnot, který se vypočítá jako:

$$\mu = \frac{1}{N} \sum_{i=1}^N f_{0i}. \quad (6.2)$$

- **Variační koeficient** – jedná se o podíl směrodatné odchylky a aritmetického průměru, uvádí se v %:

$$vk = \frac{\sigma}{\mu} * 100. \quad (6.3)$$

- **Rozsah** – jedná se o rozdíl mezi nejvyšší a nejnižší hodnotou ve vektoru.

- **Relativní rozsah** – jedná se o podíl rozsahu a aritmetického průměru (%):

$$rr = \frac{\max(f_{0_i}) - \min(f_{0_i})}{\mu} * 100, \quad (6.4)$$

kde $\max(f_{0_i})$ a $\min(f_{0_i})$ jsou největší a nejmenší prvek vektoru f_{0_i} .

- **Mezikvartilní rozsah** – udává rozdíl mezi třetím a prvním kvantilem, tzn. mezi 75. a 25. percentilem. Percentil je hodnota, pod kterou spadá toto procento všech ostatních hodnot ve vektoru [10].

Pro každý parametr bylo tedy výsledkem 5 hodnot (krom rytmických a globálních parametrů, tam je pro každý parametr výstupem vždy jedno číslo, takže tato operace nebyla nutná). U nových intonačních parametrů pak byly tyto hodnoty doplněny ještě o číslo popisující strmostní funkci (derivace této křivky), resp. o počet špiček a všechny tyto hodnoty byly doplněny do `.xlsx` tabulky k příslušným řečníkům. Pokud jsou brány tyto statistiky za jednotlivé nové parametry, **je celkový počet nových parametrů 41.**


6.3 Jádrové odhady hustoty pravděpodobnosti

U nových parametrů bylo zapotřebí, aby byly porovnány jejich rozdíly mezi zdravou a dysartrickou řečí a tyto rozdíly vhodně vykresleny. Pro vykreslení byl použit [software pro vizualizaci dysartrické řeči](#) z SPLAB (Signal Processing Laboratory) vytvořený Ústavem Telekomunikací VUT v Brně, resp. jeho část pro zobrazení hustoty pravděpodobnosti.

Jádrové odhady hustoty pravděpodobnosti (angl. kernel density estimation) jsou pro tento případ výhodné, je zde dobře vidět rozdíl v kolísání základního kmitočtu mezi zdravou a dysartrickou řečí – body jsou více rozprostřeny kolem nuly a křivka je vysoká a úzká, pokud parametr moc nekolísal, a naopak jsou body rozptýleny dále od nuly a křivka je menší a širší, pokud parametr kolísal více. **Pokud tedy graf hustoty pravděpodobnosti vykresluje pro určitý parametr úzkou křivku pro nemocné pacienty a širokou pro zdravé subjekty, je parametr pro tento popis vhodný.**


Pro výpočet jádrových odhadů hustoty pravděpodobnosti z používaného `.xlsx` souboru byl vytvořen skript `vypocet_hustoty_pravdepodobnosti.m`, který volá funkci `kernel_densityPlot.m` z SPLAB, pro vykreslení požadovaných grafů. Hned po prvním vykreslení bylo jasné, že dataset obsahuje řečníky s příliš okrajovými hodnotami (angl. outliers), viz Obr. 6.1. Vyčištění datasetu je důležitým krokem, jelikož takovéto okrajové hodnoty nejen zkreslují grafy hustoty pravděpodobnosti, ale mohou pak znehodnocovat i další analýzy. Řečníci s těmito okrajovými hodnotami byli nalezeni, ale nebylo možné je všechny z datasetu odstranit – každý z těchto řečníků byl zdánlivým „outlierm“ pro jiný parametr, takže odstranění všech by znehodnotilo celou databázi. Byl tedy vytvořen skript `out_with_outliers.m`, který využívá interní funkci Matlabu `isoutlier` k identifikaci „outlierů“. Tato funkce ale za „outliery“ označila skoro všechny řečníky, byla tedy použita její méně citlivá verze, která označuje za „outliery“ jen ty hodnoty, které jsou větší než trojnásobek směrodatné odchylky od

aritmetického průměru. Výsledek byl přibližně stejný jako u ručního odstranění, funkce byla proto dále upravena, aby počítala počet parametrů, u kterých je řečník „outlierm“, a odstranila ty řečníky, kteří jsou „outliery“, u tří a více parametrů. Výsledkem bylo odstranění sedmi řečníků z databáze, z nichž někteří ovlivňovali velké množství parametrů (> 5).



Obr. 6.1: Vyznačený „outlier“ pro jeden z parametrů.

Výsledkem bylo 41 grafů, jeden vybraný graf pro každou ze skupin lze vidět v příloze A. Graf pro *počet špiček intonační funkce* (nejlépe vycházející parametr práce) lze vidět na Obr. 6.2. Na pohled lze říci, že z hlediska skupin nových intonačních parametrů vycházely nejlépe skupiny *monohlasitosti* a *monokmitočtu* (u *monokmitočtu* byly nejznatelnější rozdíly mezi zdravou a dysartrickou řečí, ale stále zde zbývalo několik výrazných okrajových hodnot). Hned za nimi se držela *variabilita základního kmitočtu* a *intonační funkce*, nejhůře pak vyšla *variabilita krátkodobé energie*, tedy alespoň pro statistické veličiny – *počet špiček* a *strmostní funkce* vyšly dobře u všech nových intonačních parametrů. Z nových rytmických parametrů vycházel graf hustoty pravděpodobnosti nejlépe pro *USRC*, za ním bylo *TNSR* a nejhůře vyšla *tempovost*. U globálních parametrů tomu ale tak nebylo, jelikož vyšly dobře všechny, kromě *intonace/TNSR*.



Obr. 6.2: Rozložení hustoty pravděpodobnosti pro počet špiček intonační funkce.

6.4 Korelační analýza

Dalším krokem práce bylo zjištění, jak nové parametry korelují s medicínskými daty daných pacientů (jestli je přítomna např.: závislost mezi hodnotami parametrů a hodnotami dysartrického indexu daných pacientů). Pro tento účel byl opět využit skript z SPLAB – [nástroj pro korelační analýzu](#). Byl vytvořen skript `korelace.m`, který ze souboru `hodnoty_parametru.xlsx` vybral hodnoty pro nové parametry a informace o řečnících a pomocí funkce z SPLAB `correlation_analysis.m` provedl jejich korelaci. Vstupem funkce je dále typ korelace (zde nastavena Spearmanova korelace), vektor názvů nových parametrů a řád proložené křivky – zde zvolen 1. řád (lineární závislost). Výstupem funkce jsou korelační parametry ρ a p a graf vykreslující korelaci např. UPDRS III se statisticky nejvýznamnějším ze všech nových parametrů, ρ označuje Spearmanův koeficient pořadové korelace, který se vypočítá jako:

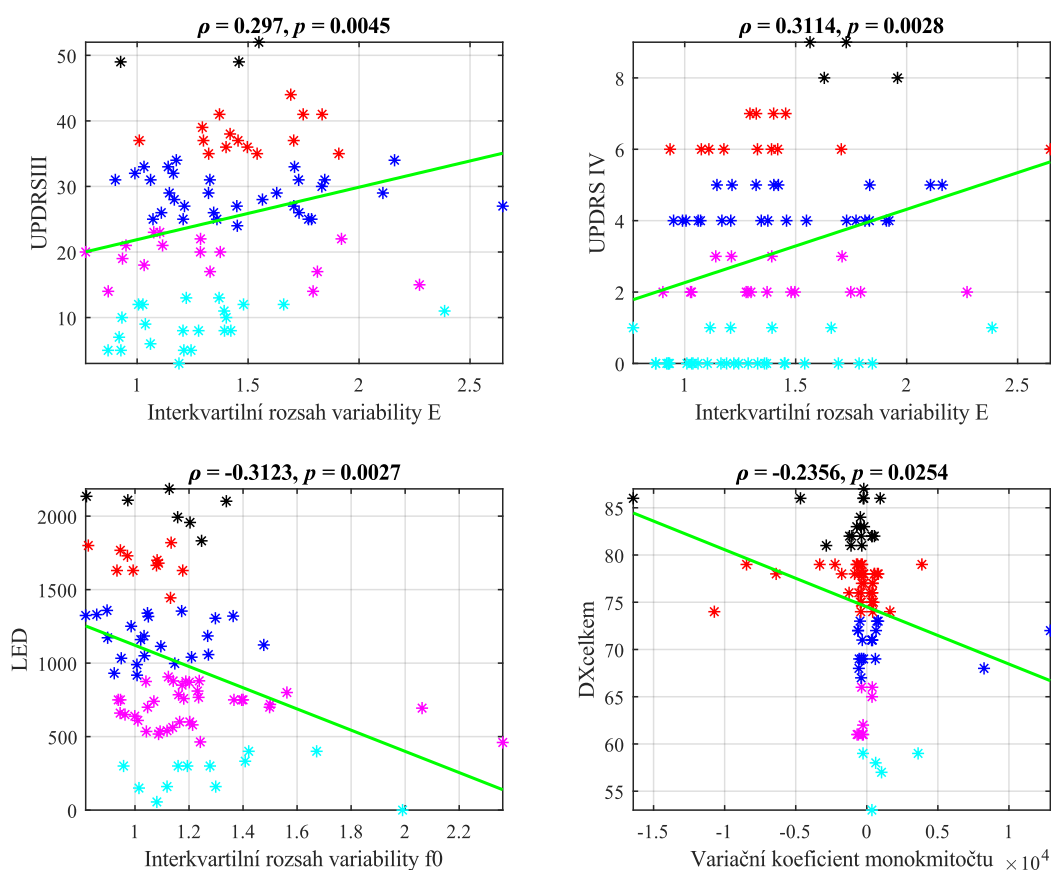
$$\rho = 1 - \frac{6 * \sum_i D_i^2}{n * (n^2 - 1)}, \quad (6.5)$$

kde D_i je rozdíl mezi pořadím hodnot dvou korelovaných vektorů, jejichž hodnoty byly předtím seřazeny vzestupně a byla jim přiřazena pořadová čísla, i je jejich pořadí a n je počet korelovaných dvojic čísel.

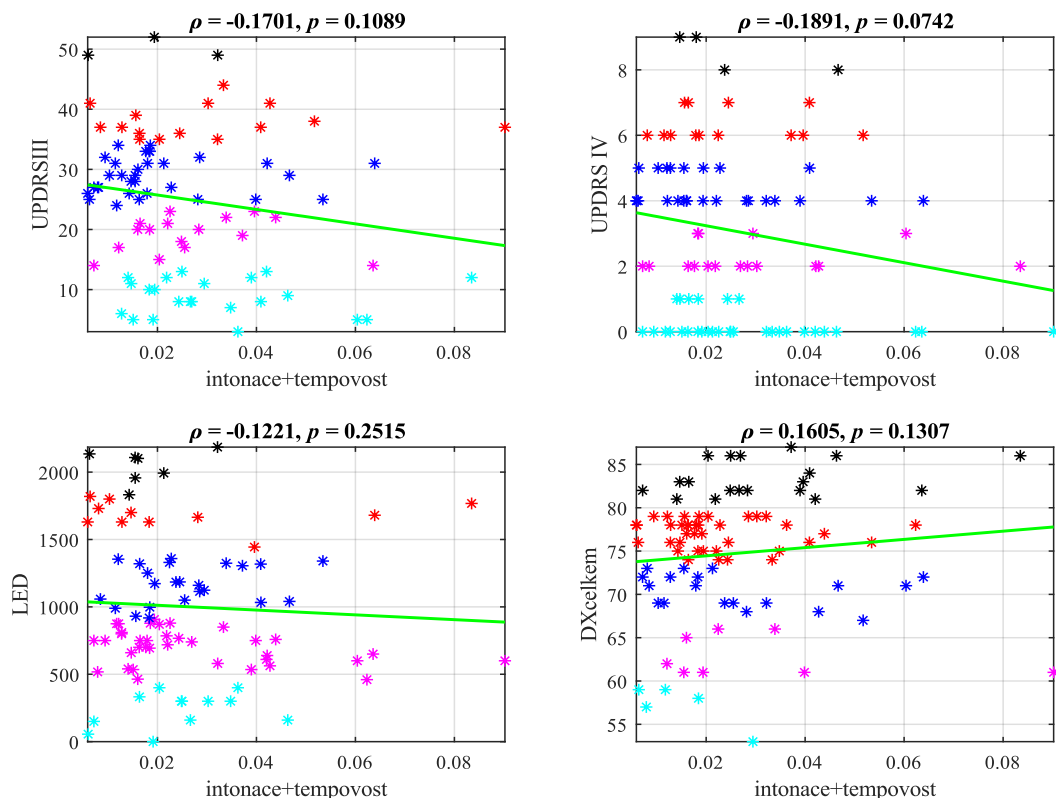
Hodnota p nám pak říká, jestli je daný výsledek Spearmanova koeficientu statisticky významný, nebo nikoliv. Pokud je $p < 0,05$, je daný parametr statisticky významný, čím menší hodnota, tím je významnější [11].

Nejdříve byla provedena korelace všech parametrů s informací, jestli je řečník zdravý, nebo nemocný. Zde vyšel jako statisticky nejvýznamnější parametr **Počet špiček variability krátkodobé energie signálu** ($p = 0,0021$, $\rho = -0,2552$).

Následně byla provedena korelace všech parametrů s dostupnými informacemi o nemoci pro všechny nemocné řečníky (UPDRS III, UPDRS IV, LED a DX). Před samotným provedením byl ještě z databáze odstraněn jeden nemocný pacient, který tam z nějakého důvodu neměl tyto informace uvedeny. Korelaci s nejvýznamnějšími parametry a hodnoty ρ a p můžeme vidět v Obr. 6.3. Na Obr. 6.4 můžeme vidět korelaci škál pouze s globálními parametry.



Obr. 6.3: Korelace klinických dat s novými parametry.



Obr. 6.4: Korelace klinických dat s globálními parametry.

Zde můžeme vidět, že program nerozpoznal ani jeden z globálních parametrů za statisticky významný, ale ve všech čtyřech případech vyšla nejlépe **kombinace Intonační funkce a Tempovosti**.

6.5 Klasifikační a regresní analýza

Nyní bylo zapotřebí otestovat nové parametry v praxi. Tím se myslí natrénovat a otestovat vhodný klasifikátor. Byla tedy provedena klasifikační a regresní analýza s novými parametry. Klasifikační i regresní analýza jsou obě podskupiny strojového učení s učitelem, to znamená, že je pro každý vstup dopředu znám správný výstup. Rozdíl mezi klasifikací a regresí je v tom, že u klasifikační analýzy se snaží klasifikátor rozdělit vstupní data do dvou nebo více **diskrétních** skupin. U regresní analýzy je výsledkem **spojitý číselný výstup** [12].

6.5.1 Klasifikační analýza

Nejdříve byla tedy provedena klasifikační analýza, kde se klasifikátor rozhodoval, jestli patří daná vstupní hodnota zdravému, nebo nemocnému subjektu. Zde byl použit [software pro klasifikační analýzu](#) z SPLAB. Software obsahuje 6 klasifikačních technik formou podsouborů, a to: metodu podpůrných vektorů, Bayesovskou síť, lineární diskriminantní analýzu, k nejblíže sousedů, klasifikační stromy a Gaussovské směsné modely. Výsledky jsou prezentovány formou matice záměn a obsahují 18 metrik z této matice.

Software dává také možnost křížové validace dat. Každý klasifikátor potřebuje dvě různé skupiny dat, a to trénovací data, na kterých se klasifikátor učí, a testovací data, na kterých se daný klasifikátor následně otestuje. Trénování i testování na stejných datech by bylo nesmyslné, je tedy třeba vstupní databázi rozdělit. Pokud je ale vstupních dat málo (jako i v našem případě) a nebylo by moudré je dále dělit, dá se použít právě zmíněná křížová validace (angl. cross validation). Ta rozdělí vstupní data na podmnožiny, poté všechny podmnožiny kromě jedné použije na natrénování a tu poslední na otestování. Tento proces se x -krát opakuje a klasifikátor se pokaždé učí na jiných podmnožinách [13]. Byl přepracován demo soubor z klasifikačního software na soubor `klasifikacni_analyza.m`, který načte hodnoty všech nových parametrů a informaci zdravý/nemocný o jednotlivých řečnících a tato data se náhodně promíchají. Dále se provádí volba klasifikačního algoritmu, požadovaných výstupních metrik a nastavení křížové validace. Poté se provede křížová validace vstupních dat, tato data se znormalizují a dojde k naučení a otestování klasifikátoru pomocí funkce `calc_classification_score.m`. Nakonec jsou vypočteny zvolené metriky a výsledky jsou uloženy do tabulky.

Kvůli neznalosti, který klasifikační algoritmus bude pro tuto problematiku nejvhodnější, byl před samotnou klasifikační analýzou proveden test, kde bylo náhodně vybráno pár nových parametrů a tyto byly postupně otestovány pro všechny klasifikační algoritmy. U všech parametrů vyšly nejlépe **klasifikační stromy**, byly tedy zvoleny jako defaultní pro celou analýzu.

Klasifikační strom (cTree) je klasifikační algoritmus, jeden z poddruhů rozhodovacích stromů. CTrees fungují tak, že si trénovací data rozdělí na oblasti, ty si označí jejich mezemi a naučí se je. Pokud je testovaná hodnota v určité dané oblasti, cTree ji přiřadí do takové skupiny, která má v dané oblasti největší zastoupení [14].

Klasifikátor poté počítá 3 vybrané metriky z matice záměn. Matice záměn (nebo také konfúzní matice) slouží k zobrazování výsledků strojového učení s učitelem. Po dokončení analýzy jsou volby klasifikátoru porovnány s pravdivými hodnotami. Z výsledků analýzy jsou zjištěny 4 základní hodnoty, a to počet **správně pozitivních (TP)** – počet správně posouzených subjektů jako nemocných, **správně negativních (TN)** – počet správně posouzených subjektů jako zdravých, **falešně pozitivních (FP)** – počet nesprávně posouzených subjektů jako nemocných a **falešně negativních výsledků (FN)** – počet nesprávně posouzených subjektů jako zdravých. Tyto hodnoty jsou dále použity k výpočtu všech ostatních metrik vycházejících z konfúzní matice. V této práci byly vybrány 3 takovéto metriky, a to:

- **Přesnost (ACC)** – jedná se o poměr všech správně posouzených výsledků ke všem výsledkům. Udáváme v %. Vypočteme jako:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} * 100. \quad (6.6)$$

Tato metrika hodnotí rozhodovací schopnost klasifikátoru mezi zdravými a nemocnými subjekty.

- **Sensitivita (SEN)** – poměr všech správně pozitivních výsledků ke všem pozitivním. Opět udáváme v %. Výpočet:

$$SEN = \frac{TP}{TP + FN} * 100. \quad (6.7)$$

Tato metrika hodnotí schopnost klasifikátoru správně rozpoznat dysartrickou řeč. V našem případě důležitý parametr, důležitější než specificita, protože je mnohem menší problém, pokud klasifikátor o někom řekne, že trpí HD, a další analýzou se ukáže, že tomu tak není, než když se rozhodne, že je zdravý a později se ukáže, že trpí například PN, když už jsou příznaky v plném proudu [15].

- **Matthewsův korelační koeficient (MCC)** – tato hodnota udává rozhodovací sílu binárního klasifikátoru. Nabývá hodnot od -1 (nejhorší rozhodovací schopnost) do 1. Počítá se jako:

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP)(FP + FN)(TN + FP)(TN + FN)}} \quad (6.8)$$

Narozdíl od přesnosti tato metrika není tak závislá na vyrovnanosti dat – tzn. pokud je skupina zdravých a nemocných subjektů výrazně odlišně velká. Příklad: pokud je 95 zdravých a jen 5 nemocných subjektů a klasifikátor rozpozná všechny zdravé správně a všechny nemocné jako zdravé, bude přesnost klasifikátoru 95 %, i když je sensitivita 0 %. MCC v tomto případě však vychází 0, takže vypovídá o průměrné rozhodovací síle [16].

Před uvedením výsledků zde ještě bude uvedeno nastavení parametrů křížové validace a samotného klasifikátoru. Křížová validace je zde stratifikovaná – to znamená, že ve všech podmnožinách by měli být stejným dílem zastoupeni zdraví i nemocní řečníci. Počet podmnožin pro každou iteraci bylo zvoleno 10 („10fold crossvalidation“ = 9 trénovacích a jedna testovací podmnožina). Počet iterací křížové validace bylo zvoleno na 20. Parametry stromu byly ponechány defaultní – rozdělovací kritérium bylo ponecháno na GDI (Gini's diversity index) a předběžná pravděpodobnost distribuce jednotlivých klasifikačních skupin byla ponechána na uniformní (stejná pro všechny skupiny). Kvůli velkému počtu parametrů bude následně uveden z každé skupiny pouze nejlépe vycházející parametr. Hodnoty jsou udány ve formátu: *hodnota ± směrodatná odchylka*. Celá tabulka je k nalezení v příloženém souboru `vysledky_klasifikacni_a_regresni_analyzy.xlsx`.

Tab. 6.2: Klasifikační analýza pro vybrané parametry.

Skupina parametrů	Konkrétní parametr	Přesnost (%)	Sensitivita (%)	MCC (-)
Variabilita základní frekvence	Mezikvartilní rozsah variability f_0	55,4214 ± 12,5627	57,681 ± 17,2718	0,1066 ± 27,5567
Variabilita krátkodobé energie	Relativní rozsah variability E	61,9571 ± 13,1673	62,6159 ± 17,8657	0,237 ± 25,7709
Monokmitočet	Variační koeficient monokmitočtu	58,3357 ± 12,7386	63,3913 ± 16,8971	0,1309 ± 27,1686
Monohlasitost	Variační koeficient monohlasitosti	59,8548 ± 12,882	63,3277 ± 16,7686	0,1713 ± 24,7883
Intonační funkce	Relativní rozsah intonační funkce	56,831 ± 12,35	61,9102 ± 17,2296	0,1157 ± 29,1965
Nové rytmické veličiny	USRC	57,7833 ± 12,7224	58,3903 ± 17,0785	0,122 ± 26,737
Globální Parametry	intonace/TSR	56,6333 ± 14,6291	60,8438 ± 18,763	0,1004 ± 25,6257

Zde vidíme, že za nejlepší nový parametr pro klasifikaci zdravý/nemocný vyšel **relativní rozsah variability krátkodobé energie**. Variabilita krátkodobé energie vycházela celkově nejlépe jako skupina (i některé její další statistické veličiny vycházely lépe než jiné parametry v této tabulce). Z globálních parametrů vyšel nejlépe **poměr intonační funkce a celkového tempa**, těsně za ním byl **poměr intonace/tempovost** (vyšší sensitivita, ale nižší přesnost a MCC).

6.5.2 Regresní analýza

Obdobným způsobem byla provedena i regresní analýza k určení síly nových parametrů ověřovat stav pacienta na škálách dysartrického indexu, UPDRS atd. Byl použit [software pro regresní analýzu](#) z SPLAB. Tento software dává na výběr 5 regresních technik: klasifikační a regresní stromy, ordinární regresi, lineární regresi, regresní analýzu pomocí podpůrných vektorů a regresi založenou na Gaussových procesech. U regresní analýzy se nepočítají klasické statistické veličiny, ale vždy chyby oproti predikovaným hodnotám. Takových metrik tento nástroj nabízí 10. Nástroj také obsahuje možnost křížové validace.

K provedení regrese byla vybrána metoda klasifikačních a regresních stromů (CART). Hlavní rozdíl mezi klasifikačním a regresním stromem je ten, že regresní strom nemá při učení trénovací data rozdělená do žádných skupin, má dostupné pouze číselné hodnoty. Rozdělení dat na oblasti proběhne stejně jako u klasifikačních stromů, ale následně se zjistí průměrná hodnota dané oblasti. U hodnot, které vyjdou v určité oblasti během testování, je pak spočítána chyba (odchylka) od tohoto oblastního průměru [14].

Metriky určující chybu jsou v této práci počítány 4, a to:

- **Střední absolutní chyba (MAE)** – jedná se o průměr absolutních diferencí mezi vypočtenou hodnotou a predikovanou hodnotou. Udává chybu v reálné hodnotě počtu bodů dané škály. Vypočítá se jako:

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - y_i|, \quad (6.9)$$

kde n je počet vypočtených hodnot, i je pořadí vypočtené hodnoty, x_i je průměr oblasti od kterého se počítá absolutní chyba a y_i je konkrétní vypočtená hodnota [17].

- **Střední kvadratická chyba (MSE)** – udává druhou mocninu rozdílu mezi predikovanou a vypočtenou hodnotou. V bodech dané škály. Výpočet:

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2, \quad (6.10)$$

kde n je opět počet vypočtených hodnot, i je pořadí vypočtené hodnoty, x_i je průměr oblasti od kterého se počítá chyba a y_i je konkrétní vypočtená hodnota. MSE je standardní metrika k rozhodování kvality výsledku u regrese. Je standardní metrikou používanou pro výpočet „cost function“ [18]. Je citlivější na změny, než MAE.

- **Chyba efektivní hodnoty (RMSE)** – udává efektivní hodnotu rozdílu mezi vypočtenou a predikovanou hodnotou. Jednotkou jsou opět body dané škály. Výpočet:

$$RMSE = \sqrt{MSE}. \quad (6.11)$$

RMSE více penalizuje velké chyby než MAE, takže je vhodným výpočtem chyby, pokud závažnost chyby na škále neroste lineárně, tzn. když je například odchylka dvacet bodů více než dvakrát horší než odchylka deseti bodů [17].

- **Relativní odhadovaná chyba (REE)** – střední absolutní chyba v procentech, která pracuje s reálným dostupným rozsahem hodnot dané škály. Je totiž velmi nepravděpodobné, že by data obsahovala subjekty v celém bodovém rozsahu. Pokud má tedy například DX rozsah 0–90 bodů a predikovaná hodnota se mine o 9 b., MAE v % by bylo 10 %, ale jelikož je v našich datech rozsah pacientů například jen 45 bodů na škále, chyba (REE) je ve skutečnosti 20 %. Výpočet (%):

$$REE = \frac{MAE}{x_{max} - x_{min}} * 100, \quad (6.12)$$

kde MAE je střední absolutní chyba, x_{max} je největší hodnota dané škály a x_{min} je její nejmenší hodnota [19].

Byl přepracován demo soubor z SPLAB na `regresni_analyza.m`. Tento skript nejdříve načte data nových parametrů a následně dojde na výběr, které parametry chceme použít a pro kterou medicínskou škálu. Dále se vybírá regresní algoritmus, požadované metriky, volba, jestli chceme použít křížovou validaci a její nastavení. Zde, stejně jako u klasifikační analýzy, byla použita „10fold“ křížová validace s dvaceti průběhy. Nastavení regresního algoritmu bylo následující: minimální počet listů stromu: 1, minimální počet větví stromu: 10, rozdělovací kritérium stromu: MSE, předběžná pravděpodobnost distribuce: zapnuta a její kritérium je opět MSE. Výsledky byly vypočteny postupně pro všechny 4 dostupné škály a výsledky pro nejlépe vycházející parametr z každé skupiny (nejnižší REE) můžeme vidět v následujících tabulkách (výsledky pro všechny parametry jsou obsaženy v tabulce v příložených souborech, viz příloha B). Nejlépe vycházející parametr pro danou škálu je označen červeně.

Tab. 6.3: Regresní analýza pro UPDRS III.

Skupina parametrů	Název parametru	Střední absolutní chyba	Střední kvadratická chyba	Chyba efektivní hodnoty	Relativní odhadovaná chyba (%)
Variabilita základní frekvence	Mezikvartilní rozsah variability f_0	11,1552 ± 2,6557	196,4892 ± 77,6691	13,7164 ± 2,8969	21,6061 ± 5,4352
Variabilita krátkodobé energie	Variační koeficient variability E	11,251 ± 2,6264	188,2804 ± 74,5123	13,4478 ± 2,734	21,6972 ± 4,8681
Monokmitočet	Variační koeficient monokmitočtu	11,5269 ± 2,7899	211,5497 ± 90,2292	14,2095 ± 3,1125	22,3902 ± 5,7296
Monohlasitost	Strmostní funkce monohlasitosti	11,9524 ± 2,7063	225,6307 ± 90,423	14,7021 ± 3,0863	23,0745 ± 5,3723
Intonační funkce	Počet špiček intonační funkce	10,6713 ± 2,3293	170,8715 ± 68,3372	12,8067 ± 2,6259	20,5764 ± 4,8812
Nové rytmické veličiny	USRC	11,5853 ± 2,6827	200,4074 ± 80,0084	13,8621 ± 2,8792	22,303 ± 5,1063
Globální Parametry	Intonace/TNSR	11,0556 ± 2,8192	197,9202 ± 88,151	13,7238 ± 3,1027	21,6999 ± 5,4837

Tab. 6.4: Regresní analýza pro UPDRS IV.

Skupina parametrů	Název parametru	Střední absolutní chyba	Střední kvadratická chyba	Chyba efektivní hodnoty	Relativní odhadovaná chyba (%)
Variabilita základní frekvence	Počet špiček variability f_0	2,3917 ± 0,5621	8,8266 ± 4,1908	2,8958 ± 0,6655	23,8435 ± 5,4922
Variabilita krátkodobé energie	Rozsah variability E	2,426 ± 0,5288	8,9557 ± 3,4701	2,9337 ± 0,5922	23,6947 ± 5,8712
Monokmitočet	Směrodatná odchylka monokmitočtu	2,704 ± 0,6785	11,3426 ± 5,025	3,284 ± 0,7488	26,6548 ± 6,3627
Monohlasitost	Variační koeficient monohlasitosti	2,476 ± 0,5331	9,3722 ± 3,3984	3,0093 ± 0,5637	25,0022 ± 5,4867
Intonační funkce	Počet špiček intonační funkce	2,4171 ± 0,4466	7,9144 ± 2,7741	2,7696 ± 0,495	24,1826 ± 4,4709
Nové rytmičné veličiny	Tempovost	2,214 ± 0,5707	7,7035 ± 3,7502	2,692 ± 0,6774	22,173 ± 5,2532
Globální Parametry	Intonace/TST	2,7101 ± 0,6308	11,4591 ± 4,7226	3,312 ± 0,7017	26,789 ± 6,2579

Tab. 6.5: Regresní analýza pro LED.

Skupina parametrů	Název parametru	Střední absolutní chyba	Střední kvadratická chyba	Chyba efektivní hodnoty	Relativní odhadovaná chyba (%)
Variabilita základní frekvence	Počet špiček variability f_0	495,7951 ± 125,5147	375634,1712 ± 164656,0261	598,5014 ± 132,3548	21,5221 ± 5,2931
Variabilita krátkodobé energie	Počet špiček variability E	484,7861 ± 109,6802	355711,1376 ± 132056,4754	586,0529 ± 110,9714	21,2156 ± 5,017
Monokmitočet	Směrodatná odchylka monokmitočtu	429,6801 ± 96,0402	288580,4606 ± 119909,1242	525,5986 ± 111,3038	18,3986 ± 4,3496
Monohlasitost	Mezikvartilní rozsah monohlasitosti	536,2299 ± 123,1252	459616,1057 ± 182122,5019	663,6941 ± 138,6447	23,5105 ± 5,7219
Intonační funkce	Počet špiček intonační funkce	466,0562 ± 97,7171	321035,588 ± 120661,4732	556,5185 ± 106,6757	20,5465 ± 4,5092

Nové rytmické veličiny	USRC	496,2889 ± 104,4333	354420,4061 ± 132558,573	584,7206 ± 112,1835	22,0335 ± 4,7468
Globální Parametry	Intonace/USRC	489,242 ± 116,117	375447,6058 ± 158292,3525	599,2156 ± 128,3379	21,7417 ± 5,4537

Tab. 6.6: Regresní analýza pro DX.

Skupina parametrů	Název parametru	Střední absolutní chyba	Střední kvadratická chyba	Chyba efektivní hodnoty	Relativní odhadovaná chyba (%)
Variabilita základní frekvence	Počet špiček variability f_0	7,0669 ± 1,7614	80,6293 ± 35,8676	8,7363 ± 2,0804	20,0035 ± 5,2133
Variabilita krátkodobé energie	Počet špiček variability E	6,6922 ± 1,9349	79,5558 ± 38,5969	8,6383 ± 2,2273	18,8822 ± 5,2428
Monokmitočet	Rozsah monokmitočtu	6,8098 ± 1,6415	80,2167 ± 37,6196	8,6958 ± 2,1502	19,7621 ± 5,4468
Monohlasitost	Relativní rozsah monohlasitosti	6,8154 ± 1,6213	71,3578 ± 30,2714	8,2476 ± 1,8308	19,6849 ± 5,0122
Intonační funkce	Počet špiček intonační funkce	6,2704 ± 1,6073	63,3071 ± 29,6401	7,7344 ± 1,8716	17,8816 ± 4,8699
Nové rytmické veličiny	USRC	6,55 ± 1,6825	67,7018 ± 32,3201	7,9734 ± 2,0367	18,7431 ± 4,638
Globální Parametry	Intonace/TST	7,1344 ± 1,7783	84,1788 ± 41,6612	8,9013 ± 2,2293	20,4391 ± 5,2351

6.5.3 Testování pro všechna data

Nakonec byla ještě provedena klasifikace a regrese pro data všech parametrů najednou. To znamenalo nerozlišovat jednotlivé nové parametry, ale vzít všechna vypočtená data a naučit s nimi klasifikátor. Byla provedena drobná úprava ve skriptech `klasifikacni_analyza.m` a `regresni_analyza.m` – skripty obsahují cyklus „for“, kdy proběhne tolik iterací, kolik je parametrů a při každé další iteraci se znova učí klasifikátor a počítají se metriky pro onen daný parametr. Zde byla provedena pouze drobná změna, kdy byla při každé iteraci použita data všech parametrů najednou a výsledek ze všech iterací (počet průběhů cyklu stále jako počet parametrů, tedy 41) byl zprůměrován. Výsledky můžeme vidět v následujících tabulkách.

Tab. 6.7: Klasifikační analýza pro všechna data.

Přesnost (%)	Sensitivita (%)	MCC
51,5785 ± 12,3828	55,4944 ± 16,9915	-0,0016 ± 26,1955

Tab. 6.8: Regresní analýza pro všechna data

	Střední absolutní chyba	Střední kvadratická chyba	Chyba efektivní hodnoty	Relativní odhadovaná chyba (%)
UPDRS III	13,4598 ± 2,7940	257,9276 ± 93,9926	15,7881 ± 2,9428	25,8989 ± 5,4343
UPDRS IV	2,7178 ± 0,5601	10,5644 ± 3,6675	3,2003 ± 0,5684	27,1492 ± 5,582
LED	565,1939 ± 132,9456	502414,8132 ± 221425,5831	691,5462 ± 155,6816	24,7938 ± 5,7634
DX	7,5443 ± 1,9344	94,4141 ± 45,0719	9,4271 ± 2,3579	21,4919 ± 5,5431

Předpokladem bylo, že při vyšším objemu trénovacích dat, která má rozhodovací algoritmus dostupná, by měl automaticky dosahovat lepších výsledků. To se ale nestalo. Vidíme, že některé samostatné nové parametry dosahovaly lepších výsledků než testování pro všechna data (kap. 6.5). Nejpravděpodobnějším vysvětlením je, že některé nové parametry jsou pro tuto problematiku vyloženě nevhodné a jejich hodnoty kazí celkové výsledky. Dalším krokem a zároveň ověřením tohoto tvrzení tedy bylo provedení sekvenčního výběru parametrů.

6.6 Sekvenční výběr parametrů

Ne vždy znamená více parametrů lepší výsledky klasifikace. Při malém počtu dat, nebo velkém počtu parametrů může nastat tzv. „přefitování“ (angl. overfitting). „Přefitovaný“ model sice nejlépe popisuje trénovací data, ale je příliš závislý na těchto konkrétních datech a pro budoucí testovací data vykazuje horší výsledky [20]. Proto se často provádí sekvenční výběr parametrů, kdy jsou zjišťovány nejlepší kombinace parametrů. Pro tento účel byl použit [software pro sekvenční selekci příznaků](#) z SPLAB. Byly vytvořeny skripty `sffs_klasifikace.m` a `sffs_regrese.m`. Vstupem do skriptů je kromě použitého klasifikačního algoritmu a nastavení křížové validace také skóre, které značí metriku, podle které se má výběr parametrů řídit. Dále N – maximální počet parametrů, které mohou být použity najednou a t , což je maximální počet parametrů, které mohou být přidány do celkové skupiny parametrů, aniž by došlo ke zlepšení (po přesáhnutí tohoto počtu se sekvenční selekce vrací k předchozímu nejlepšímu výsledku u menšího počtu parametrů). Nastavení klasifikačního a regresního algoritmu a křížové validace bylo ponecháno stejné jako v kap. 6.5. N bylo nastaveno na počet dostupných parametrů (maximum) a t bylo nastaveno na 2 (pokud se přidají 3 parametry a nedojde ke zlepšení, tak se selektor vrací k předchozí nejlepší kombinaci).

U selekce parametrů pro klasifikaci zdravý/nemocný se skóre řídilo pomocí TSS, což je „trade-off“ mezi sensitivitou a specificitou. Selektor se tedy snažil vybrat takovou kombinaci parametrů, aby byla kombinace sensitivity a specificity co jak největší. Selektor vybral pro klasifikaci kombinaci následujících devíti parametrů:


- *Variační koeficient variability f_0*
- *Relativní rozsah variability E*
- *Mezikvartilní rozsah variability E*
- *Strmostní funkce monokmitočtu*
- *Mezikvartilní rozsah monohlasitosti*
- *Směrodatná odchylka intonační funkce*
- *TNSR*
- *Tempovost*
- *Intonace/TNSR*

Výsledky pro kombinaci těchto parametrů jsou následující:

Tab. 6.9: Výsledky sekvenční selekce parametrů pro klasifikační analýzu.

Přesnost (%)	Sensitivita (%)	Specifita (%)
67,4468	68,4615	65,6

Vidíme nárůst přesnosti oproti použití všech 41 parametrů, viz Tab. 6.7. V následujícím grafu je vidět průběh změn, které selektor provedl:



Obr. 6.5: Průběh provádění změn selektorem u výběru parametrů pro klasifikaci.


V grafu lze vidět místo s nejlepší kombinací hodnot (označené hvězdičkou). Tam, kde je skóre (SCR) 100 %, byla nejlepší kombinace sensitivity a specificity. Černé čáry označují místo, kde se selektor rozhodl přidat do kombinace další parametr a čísla u nich počet parametrů v tu chvíli.

U selekce parametrů pro regresní škály se skóre řídilo pomocí střední absolutní chyby. Selektor vybral pro regresní analýzu s UPDRS III následující kombinaci parametrů:

- *Variační koeficient variability f_0*
- *Mezikvartilní rozsah variability f_0*
- *Variační koeficient monokmitočtu*
- *Počet špiček intonační funkce*

Tab. 6.10: Výsledky sekvenční selekce parametrů pro regresní analýzu UPDRS III.

Střední absolutní chyba	Střední kvadratická chyba	Chyba efektivní hodnoty	Relativní odhadovaná chyba (%)
10,5376 ± 3,1258	193,4439 ± 104,9026	13,4372 ± 3,5968	20,2646 ± 6,0112



Obr. 6.6: Průběh změn u sekvenčního výběru parametrů pro UPDRS III.


Zde vidíme hvězdičkou označené místo s nejnižším *MAE*. Na ose *y* je vždy kromě momentální hodnoty zaznačena i směrodatná odchylka.

Sekvenční selekce dále pro UPDRS IV vybrala následující kombinaci parametrů:

- *Strmostní funkce variability f_0*
- *Směrodatná odchylka monohlasitosti*
- *Rozsah monohlasitosti*
- *Mezikvartilní rozsah monohlasitosti*
- *Tempovost*
- *Intonace/TNSR*

Tab. 6.11: Výsledky sekvenční selekce parametrů pro regresní analýzu UPDRS IV.

Střední absolutní chyba	Střední kvadratická chyba	Chyba efektivní hodnoty	Relativní odhadovaná chyba (%)
1,8977 ± 0,4859	5,8292 ± 2,6854	2,3548 ± 0,5342	18,9769 ± 4,8593




Obr. 6.7: Průběh změn u sekvenčního výběru parametrů pro UPDRS IV.

Pro škálu denní dávky L-DOPA vybral selekční výběr pouze jeden parametr, a to *směrodatnou odchylku monokmitočtu*.

Tab. 6.12: Výsledky sekvenční selekce parametrů pro regresní analýzu LED.

Střední absolutní chyba	Střední kvadratická chyba	Chyba efektivní hodnoty	Relativní odhadovaná chyba (%)
426,0795 ± 96,6218	277390,3697 ± 107749,0836	516,4889 ± 103,3584	18,7288 ± 4,2471



Obr. 6.8: Průběh změn u sekvenčního výběru parametrů pro LED.

Pokud se podíváme do přiloženého souboru `vysledky_klasifikacni_a_regresni_analyzy.xlsx`, tak vidíme, že tento parametr má mnohem lepší výsledky pro LED než ostatní parametry. Z grafu průběhu jde vidět, že se program ukončil, jelikož ani po dvoj, troj a čtyřkombinaci nedošlo ke zlepšení výsledků.


Pro škálu dysartrického indexu vybral sekvenční výběr kombinaci těchto dvou parametrů:

- *Směrodatná odchylka intonační funkce*
- *Variační koeficient intonační funkce*

Výsledky:

Tab. 6.13: Výsledky sekvenční selekce parametrů pro regresní analýzu DX.

Střední absolutní chyba	Střední kvadratická chyba	Chyba efektivní hodnoty	Relativní odhadovaná chyba (%)
$6,2408 \pm 1,7550$	$69,7157 \pm 38,2246$	$8,0526 \pm 2,2125$	$17,8308 \pm 5,0144$



Obr. 6.9: Průběh změn u sekvenčního výběru parametrů pro DX.

7 Závěr

V této práci byl uveden a otestován celkový počet 41 nových parametrů pro zpracování dysprozodie u pacientů s Parkinsonovou nemocí. V rámci práce byla nejdříve popsána problematika Parkinsonovy nemoci, hypokinetické dysartrie, dysprozodie a analýzy dysartrické řeči (kap. 1–3). Dále byly popsány parametry, které se pro kvantifikaci dysprozodie běžně používají (kap. 4), a také teoretický popis nových parametrů (kap. 5).

Celá praktická část práce byla vypracována v prostředí Matlab. Pro vypracování praktické části práce byly použity nahrávky z české databáze PARCZ obsahující nahrávky pacientů s PN i zdravé subjekty, konkrétně nahrávky básně ve formátu .wav, a také .xlsx soubor s klinickými metadaty o jednotlivých řečnících, viz kap. 6.1.

Databáze byla nejdříve upravena, aby nahrávky seděly s poskytnutými medicínskými informacemi. Poté byl vytvořen skript `DP_vypocet_vsech_parametru.m`, který prvně vypočetl hodnoty konvenčních parametrů pomocí sbírky externích funkcí z SPLAB (Signal processing laboratory od zaměstnanců FEKT VUT v Brně) a poté za pomoci vytvořených programů `pitch_variability.m`, `energy_variability.m`, `speech_monopitch.m`, `speech_monoloudness.m`, `speech_intonation.m`, `novel_time_characteristics.m` a `global_parameter.m` a s využitím statistických veličin vypočetl hodnoty všech čtyřiceti jedna nových parametrů, viz kap. 6.2. Tyto hodnoty byly následně doplněny do tabulky k příslušným řečníkům.

Dalším krokem byl výpočet hustoty pravděpodobnosti pro každý z nových parametrů, viz kap. 6.3. Pro tento účel byl vytvořen skript `vypocet_hustoty_pravdepodobnosti.m`, který volá funkci `kernel_densityPlot.m` z SPLAB a s jeho pomocí vykresluje 41 grafů hustoty pravděpodobnosti, pro každý z parametrů. Tyto grafy ale byly poměrně nepřehledné, obsahovaly totiž velké množství příliš okrajových hodnot („outlierů“ – jednalo se většinou o řečníky, kteří již byli v extrémním stádiu PN). K odstranění těchto hodnot byl vytvořen skript `out_with_outliers.m`, který za „outliery“ rozpoznal všechny hodnoty, které byly větší než trojnásobek směrodatné odchylky mediánu, následně sečetl pro kolik parametrů je daný řečník „outliery“ a odstranil z databáze ty, kteří měli okrajové hodnoty u tří a více parametrů. Takto bylo z databáze odstraněno 7 řečníků a výpočet hustoty pravděpodobnosti byl proveden znovu. Obecně v rámci skupin nových parametrů vyšly nejlépe grafy ***monohlasitosti***, ***monokmitočtu*** a ***globálních parametrů***. Vybraný graf pro každou skupinu parametrů lze vidět v příloze A.

Dále byla vypočtena korelace nových parametrů s dostupnými klinickými škálami pacientů (DX, UPDRS III, UPDRS IV, LED – viz kap. 6.4). Byl vytvořen skript `korelace.m`, který používá `correlation_analysis.m` z SPLAB k nalezení Spearmanova koeficientu pořadové korelace a jeho p hodnoty a vykresluje pro každou škálu nejvíce korelující parametr. Nejlépe korelující parametr pro obě škály UPDRS vyšel ***mezikvartilní rozsah variability krátkodobé energie signálu***, nejlépe korelující parametr

pro LED byl *mezikvartilní rozsah variability základní frekvence signálu* a jako nejlépe korelující parametr pro DX vyšel *variační koeficient monokmitočtu*, viz Obr. 6.3. Všechny tyto parametry byly rozpoznány za statisticky významné ($p < 0,05$). U škál UPDRS IV a LED bylo p menší než 0,002. Stejná analýza byla provedena ještě samostatně pro globální parametry. Zde vyšel pro všechny škály nejlepší jeden parametr, a to *poměr intonace a tempovosti*, který sice nebyl rozpoznán za statisticky významný, ale velmi se blížil (0,07 pro UPDRS IV), viz Obr. 6.4.

Poté byla provedena klasifikační analýza, kdy byl na dostupných vypočtených datech jednotlivých parametrů za pomoci křížové validace natrénován a následně otestován jednoduchý rozhodovací strom. Výsledky klasifikace jsou prezentovány formou přesnosti (ACC), sensitivity (SEN) a Matthewsova korelačního koeficientu (MCC), viz kap. 6.5.1. Byl vytvořen skript *klasifikacni_analyza.m*, který používá funkci *perf_classification.m* z SPLAB k natrénování a otestování stromu a poté funkci *calc_classification_score.m* k výpočtu požadovaných metrik. Jako nejlepší parametr pro klasifikaci mezi zdravými a nemocnými subjekty vyšel *relativní rozsah variability krátkodobé energie signálu* (ACC = 61,9571 % \pm 13,1673 %, SEN = 62,6159 % \pm 17,8657 %, MCC = 0,23704 \pm 25,7709 %). I když byly nejlepším a 2. nejlepším parametrem *relativní* a *mezikvartilní rozsah variability E*, celkově nejlépe vycházející skupinou parametrů zde byla *monohlasitost*. Hned za ní byla *variabilita E* a *monofrekvence*. V intonačních parametrech lze pozorovat spíše než spojitosti v rámci skupin parametrů určitý vzorec podle použité statistické veličiny: například směrodatná odchylka vyšla všude, kromě *monohlasitosti*, jako jedna z nejhorších metrik, zatímco např. *relativní rozsah* naopak vyšel dobře všude kromě *variability f₀*. Nové rytmické veličiny se pro tuto problematiku příliš neosvědčily. Z globálních parametrů nejlépe vyšly *poměr intonace a TSR* (ACC = 56,6333 % \pm 14,6291 %, SEN = 60,8438 % \pm 18,763 %, MCC = 0,1004 \pm 25,6257 %) a *intonace a tempovosti* (ACC = 53,7667 % \pm 12,522 %, SEN = 61,504 % \pm 16,4475 %, MCC = 0,0419 \pm 25,3402 %).

Pro regresní analýzu byl vytvořen skript *regresni_analyza.m*, který využívá funkce z SPLAB *perf_regression.m* k provedení regresní analýzy a *calc_regression_score.m* k výpočtu chyb. Regrese je prováděna metodou klasifikačních a regresních stromů (CART) a chyba je udávána čtyřmi metrikami: střední absolutní chybou (MAE), střední kvadratickou chybou (MSE), chybou efektivní hodnoty (RMSE) a relativní odhadovanou chybou (REE), viz kap. 6.5.2. Nejlepším parametrem pro škálu UPDRS III byl *počet špiček intonační funkce* (MAE = 10,6713 \pm 2,3293, MSE = 170,8715 \pm 68,3372, RMSE = 12,8067 \pm 2,6259, REE = 20,5764 % \pm 4,8812 %). Co se týče skupin parametrů, tak kromě zmíněné *intonační funkce* vycházela dobře i *variabilita krátkodobé energie*. Naopak nejhůře se projevíly *mono-parametry*. Z globálních parametrů by bylo dobré vyzdvihnout alespoň *poměr intonace a TNSR* (MAE = 11,0556 \pm 2,8192, MSE = 197,9202 \pm 88,151, RMSE = 13,7238 \pm 3,1027, REE = 21,6999 % \pm 5,4837 %). Pro škálu UPDRS IV se parametry osvědčily hůře, zde se REE spíše blížil 30 %. Jako nejlepší parametr (REE téměř o 2 % nižší, než 2. nejlepší parametr)

zde vyšla **tempovost** ($MAE = 2,214 \pm 0,5707$, $MSE = 7,7035 \pm 3,7502$, $RMSE = 2,692 \pm 0,6774$, $REE = 22,173 \% \pm 5,2532 \%$). Celkově v rámci skupin se skupina **nových rytmických parametrů** projevila jako nejlepší, všechny 3 parametry vyšly jako jedny z nejlépe vycházejících. Nejhorše vycházející skupina byla jednoznačně **monokmitočet**. Také **globální parametry** a **monohlasitost** se neosvědčily. U ostatních skupin záleželo na statistické veličině, několik nejlépe vycházejících: **počet špiček variability základní frekvence** ($REE = 23,8435 \% \pm 5,492 \%$), **rozsah variability krátkodobé energie** ($REE = 23,6947 \% \pm 5,8712 \%$) a opět **počet špiček intonační funkce** ($REE = 24,1826 \% \pm 4,4709 \%$). U škály LED byly největší rozdíly v rámci jedné skupiny parametrů (REE v rozmezí $18,4 \% - 28,1 \%$ mezi parametry monokmitočtu). Zde je třeba brát v potaz, že dávky levodopy podávané pacientům nejsou exaktně vypočtené hodnoty, spíše namátkou vybrané množství podle současného stavu pacienta. I tak zde ale některé skupiny parametrů vycházely lépe než jiné. Jako nejlépe vycházející parametr zde vyšla **směrodatná odchylka monokmitočtu** ($MAE = 429,6801 \pm 96,0402$, $MSE = 288580,4606 \pm 119909,1242$, $RMSE = 525,5986 \pm 111,3038$, $REE = 18,3986 \% \pm 4,3496 \%$). Ve skupině monokmitočtu ale máme největší skoky, **relativní rozsah monokmitočtu** je parametr s největší chybou v rámci LED vůbec ($REE = 28,108 \% \pm 6,6242 \%$). Podobný trend sledujeme i u **intonační funkce**, jejíž **počet špiček** vyšel jako druhý nejlepší parametr ($REE = 20,5465 \% \pm 4,5092 \%$), a naopak její **mezikvartilní rozsah** vyšel jako jeden z nejhorších parametrů ($REE = 26,2492 \% \pm 5,8255 \%$). Všechny 3 **nové rytmické veličiny** se zde osvědčily, také některé **globální parametry** zde měly dobré výsledky, nejlepší byl **poměr intonace a USRC** ($REE = 21,7417 \% \pm 5,4537 \%$). **Variabilita krátkodobé energie** měla také u všech statistik kromě strmostní funkce dobrý výsledek (REE lehce přes 20%). V rámci statistických veličin lze vyzorovat, že **počet špiček** vycházel jako jeden z nejlepších parametrů a **relativní rozsah** naopak u většiny jako jeden z nejhorších. Nakonec pro škálu dysartrického indexu parametry prokázaly nejlepší výsledky ze všech čtyř škál. Nejlépe vyšel parametr **počet špiček intonační funkce** ($MAE = 6,2704 \pm 1,6073$, $MSE = 63,3071 \pm 29,6401$, $RMSE = 7,7344 \pm 1,8716$, $REE = 17,8816 \% \pm 4,8699 \%$). Těsně za ním byla **směrodatná odchylka intonační funkce** ($MAE = 6,1798 \pm 1,5472$, $MSE = 65,7752 \pm 36,1735$, $RMSE = 7,831 \pm 2,1149$, $REE = 18,0183 \% \pm 5,1068 \%$). V rámci skupin nových intonačních parametrů nebyly velké rozdíly, výsledky se lišily především podle použité statistiky, bez viditelnějšího vzorce. Kromě zmíněné **intonační funkce** ale dobře vycházely především **nové rytmické veličiny** (hlavně **TNSR** a **USRC**). Z globálních veličin pak vyšel nejlépe **poměr intonace/TST** ($REE = 20,4391 \% \pm 5,2351 \%$).

Po předchozí analýze bylo ještě provedeno testování pro všechna data všech parametrů najednou. Byly vytvořeny skripty `klasifikacni_analyza_vsechno.m` a `regresni_analyza_vsechno.m` úpravou skriptů klasifikační a regresní analýzy (kap. 6.5.3). Výsledky klasifikační analýzy byly: $ACC = 51,5785 \% \pm 12,3828 \%$, $SEN = 55,4944 \% \pm 16,9915 \%$, $MCC = -0,0016 \pm 26,1955 \%$. Ve srovnání se samostatnými parametry byly tyto výsledky velmi průměrné (přesnost se pohybovala mezi 42% a 62%). Podobně tomu bylo i u regresní analýzy pro všechna data, kde byly výsledky u všech škál horší než zprůměrované výsledky jednotlivých hodnot (REE

u UPDRS III pro všechna data = 25,9 %, průměr REE jednotlivých parametrů u UPDRS III = 23,9 %).

Nakonec byl v návaznosti na výsledek předchozí kapitoly proveden selekční výběr parametrů, kvůli zjištění nejlepší kombinace parametrů pro danou problematiku. Byly vytvořeny skripty `sffs_klasifikace.m` a `sffs_regrese.m`, které využívají `SFFS_cls.m` a `SFFS_reg.m` z SPLAB k provedení dopředné selekce parametrů. Také byly použity skripty `plot_sffs_cls_progress.m` a `plot_sffs_reg_progress.m` k vykreslení průběhu výběru parametrů, viz kap. 6.6. U výběru parametrů pro klasifikaci vyšla nejlépe kombinace těchto devíti parametrů: **variačního koeficientu variability f_0** , **relativního rozsahu variability E** (nejlépe vycházející samostatný parametr), **mezikvartilního rozsahu variability E** (2. nejlépe vycházející samostatný parametr), **strmostní funkce monokmitočtu**, **mezikvartilního rozsahu monohlasitosti**, **směrodatné odchylky intonační funkce**, **TNSR**, **tempovosti** a poměru **intonační funkce/TNSR**. Výsledky kombinace byly: ACC = 67,4468 % (**rel. rozs. var. E** = 61,9571 %), SEN = 68,4615 % (**r. r. v. E** = 62,6159 %), SPE = 65,6 %. Vidíme tedy nárůst o necelých 6 % od nejlepšího samostatného parametru. U regresní analýzy byly pro škálu UPDRS III vybrány tyto parametry: **variační koeficient variability f_0** , **mezikvartilní rozsah variability f_0** , **variační koeficient monokmitočtu** a **počet špiček intonační funkce** (nejlepší samostatný parametr). Výsledky jsou následující: MAE = $10,5376 \pm 3,1258$, MSE = $193,4439 \pm 104,9026$, RMSE = $13,4372 \pm 3,5968$, REE = $20,2646 \pm 6,0112$ %. Zde pozorujeme téměř nepatrné zlepšení oproti samotnému **počtu špiček intonace** (MAE nižší pouze o 0,1337 a REE o 0,3118 %, na úkor MSE a RMSE, které jsou dokonce vyšší). Pro škálu UPDRS IV byla vybrána tato kombinace parametrů: **strmostní funkce variability f_0** , **směrodatná odchylka monohlasitosti**, **rozsah monohlasitosti**, **mezikvartilní rozsah monohlasitosti**, **tempovost** (nejlepší samostatný parametr) a poměr **intonace/TNSR**. Výsledek kombinace byl následující: MAE = $1,8977 \pm 0,4859$, MSE = $5,8292 \pm 2,6854$, RMSE = $2,3548 \pm 0,5342$, REE = $18,9769 \pm 4,8593$ %. Zde již bylo zlepšení znatelnější (REE menší o 3,1961 %). Zajímavý byl výsledek pro škálu denní dávky levodopy. Skript byl totiž nastaven, aby se vrátil k nejlepšímu předchozímu výsledku a ukončil se, pokud 3x přidá do kombinace další parametr a ani jednou se nezlepší. Zde se to ale narozdíl od ostatních škál stalo již při prvním parametru. Ani kombinace čtyř různých parametrů nepodávala lepší výsledky jako samostatně nejlepší parametr: **směrodatná odchylka monokmitočtu**, viz Obr. 6.8. Výsledky zde: MAE = $426,0795 \pm 96,6218$, MSE = $277390,3697 \pm 107749,0836$, RMSE = $516,4889 \pm 103,3584$, REE = $18,7288 \pm 4,2471$ %. Podobný případ nastal u poslední škály DX. Jediná kombinace s vyšším MAE než počet špiček intonační funkce byla kombinace **směrodatné odchylky** a **variačního koeficientu intonační funkce**. MAE = $6,2408 \pm 1,7550$, MSE = $69,7157 \pm 38,2246$, RMSE = $8,0526 \pm 2,2125$, REE = $17,8308 \pm 5,0144$ %. Právě **směrodatná odchylka intonační funkce** je zde parametr s nejnižším MAE ze všech, i když nemá REE tak nízké jako parametr **počet špiček intonace** – kombinace ale dosahuje i lepšího REE (ale jen o 0,05 %). Kvůli tomu, že se o kvalitě parametru v kap. 6.5.2 nerozhodovalo podle MAE, jako zde, ale podle REE, je

toto jediná skupina parametrů, ve které není obsažen samotný nejlépe vycházející parametr z předchozí kapitoly.

Všechny výše popsané skripty, tabulky se všemi vypočtenými hodnotami a všechny výsledné grafy lze nalézt zabalené v souboru `diplomova_prace.zip`, který byl elektronicky odevzdán s touto prací a také je vypálen na příloženém CD. Příloha A obsahuje po jednom vybraném grafu jádrového odhadu hustoty pravděpodobnosti pro každou skupinu nových parametrů. Pro podrobnější popis obsahu CD, viz příloha B.

Jako závěrečné shrnutí a zhodnocení kvality nových prozodických parametrů by bylo dobré podotknout, že i když se žádný z nových parametrů neukázal jako vyložená „trefa do černého“, bylo zde několik jmen parametrů, která se stále opakovala. Nesmíme zde opomenout především parametr ***počet špiček intonační funkce***, který se ukázal jako jeden z nejuniverzálnějších a nejlepších parametrů (minimálně pro regresní analýzu) a byl tedy nejspíše dobrý krok, že na něm byly postaveny všechny ***globální parametry*** (z problémů tohoto parametru u klasifikační analýzy může vycházet stejný problém globálních parametrů u klasifikace, stálo by za to experimentovat s jiným základem pro globální parametr pro rozhodování o zdraví/nemoci). Je zajímavé, že právě tento parametr (a dobře vycházely většinou všechny parametry založené na funkci `findpeaks`) dokáže dobře popisovat různé medicínské škály, i když je jeho reálný rozsah pouze 0–6 (tzn. 7 diskrétních hodnot). Pro zhodnocení jednotlivých skupin – ze skupiny nových parametrů založených na základním kmitočtu a krátkodobé energii signálu by bylo nejspíše lepším krokem přiklonit se k parametrům ***variability f_0*** a ***E***, než k ***mono-parametrům***. Jednoduše proto, že vycházely dobře ve více případech, vždy ale záleželo na konkrétním případě a použité statistické veličině. Bylo by na druhou stranu nespravedlivé u ***mono-parametrů*** opomenout kvalitu parametru ***směrodatná odchylka monokmitočtu*** pro regresi u L-DOPA, kde tento parametr dosahoval mnohem lepších výsledků než všechny ostatní. Skupina ***intonační funkce*** (kombinace ***f_0*** a ***E*** do jednoho parametru) rozhodně stojí za další testování, nejen kvůli již zmíněnému ***počtu špiček***, ale i např. ***směrodatná odchylka intonační funkce*** se objevila v nejlepších výsledcích více než jednou. Dále skupina ***nových rytmických parametrů*** (kombinující tempo a rytmus dohromady) se také osvědčila jako smysluplná. Za nejlepší by se u této skupiny dal považovat parametr ***tempovost***, který se objevoval v nejlepších výsledcích opakovaně a hlavně se jednalo o nejlepší parametr ze všech pro regresní analýzu u škály UPDRS IV. Proto je zajímavé, že u skupiny ***globálních parametrů*** se kombinace ***počtu špiček intonační funkce*** a ***tempovosti*** příliš neosvědčila. Sice vyšla jako nejlepší globální parametr u korelace s medicínskými metadaty, ale u samotné regresní analýzy s těmito škálami pak vycházela jako jeden z nejhorších parametrů. Za obecně nejlepší globální parametr by se dal považovat poměr ***počet špiček intonační funkce*** a ***TNSR***. ***Globální parametry*** popsané v této práci nedosahovaly nijak skvělých výsledků, toto ale není žádný pokus je zavrhnout, spíše by stála za vyzkoušení kombinace např. zmíněného parametru ***počet špiček intonační funkce*** s jinými rytmickými parametry, nebo stávající parametry zkombinovat jiným způsobem. Také do dobře vycházející ***tempovosti*** by se

dalo vyzkoušet zapojit *intonaci řeči* jiným způsobem do možná lepšího globálního parametru, než je uveden v této práci.

V budoucnosti by se na práci provedenou v této DP dalo navázat především dalším navrhováním a testováním nových globálních parametrů. Z výsledků vidíme, že globální parametry pro zpracování všech složek dysprozodie mají význam, a i když nevyšly nejlépe ze všech, nebylo by nasnadě zkusit nejlépe vycházející parametry pro jednotlivé složky dysprozodie zkombinovat do jednoho co jak nejúčinnějšího parametru. Takovýto jeden nejlepší globální parametr by pak mohl při správném vykreslení poskytovat dostatečnou objektivní oporu pro klinického logopeda při vyšetření dysartrie.

Seznam použitých zdrojů

- [1] ROTH, Jan, Evžen RŮŽIČKA a Petr KAŇOVSKÝ. *Parkinsonova nemoc a parkinsonské syndromy*. Praha: Galén, c2000. Extrapiramidová onemocnění. ISBN 80-7262-048-7.
- [2] CSÉFALVAY, Zsolt a Viktor LECHTA. *Diagnostika narušené komunikační schopnosti u dospělých*. Praha: Portál, 2013. ISBN 978-80-262-0364-3.
- [3] BRABENEC, L., J. MEKYSKA, Z. GALAZ a Irena REKTOROVA. Speech disorders in Parkinson's disease: early diagnostics and effects of medication and brain stimulation. *Journal of Neural Transmission* [online]. 2017, vol. **124**(3), 303-334 [cit. 2018-11-03]. DOI: 10.1007/s00702-017-1676-0. ISSN 0300-9564. Dostupné z: <http://link.springer.com/10.1007/s00702-017-1676-0>
- [4] GALAZ, Z., J. MEKYSKA, Z. MZOUREK, Z. SMEKAL, I. REKTOROVA, I. ELIASOVA, M. KOSTALOVA, M. MRACKOVA, D. BERANKOVA. Prosodic analysis of neutral, stress-modified and rhymed speech in patients with Parkinson's disease. *Computer methods and programs in biomedicine* [online]. 2016, vol. **127**, 301-317, Amsterdam: Elsevier Science Publishers, 1985-. ISSN 0169-2607. Dostupné z: <https://doi.org/10.1016/j.cmpb.2015.12.011>
- [5] ROUBÍČKOVÁ, Jaroslava. *Test 3F: dysartrický profil*. 3., dopl. a přeprac. vyd., (V nakl. Galén 1.). Praha: Galén, c2011. ISBN 978-80-7262-714-1.
- [6] MEKYSKA J., E. JANOUSKOVA, P. GOMEZ-VILDA, Z. SMEKAL, I. REKTOROVA, I. ELIASOVA, M. KOSTALOVA, M. MRACKOVA, J. B. ALONSO-HERNANDEZ, M. FAUNDEZ-ZANUY, K. LOPEZ-DE-IPINA. Robust and komplex approach of pathological speech signal analysis. *Neurocomputing* [online]. 2015, vol. **167**, 94-111, Amsterdam: Elsevier Science Publishers. ISSN 0925-2312. Dostupné z: <https://doi.org/10.1016/j.neucom.2015.02.085>
- [7] DANKOVIČOVÁ, Dana. *Articulation rate variation within the intonation phrase in Czech and English* [online]. Vědecký článek, 14th International Congress of Phonetic Sciences, San Francisco. [cit. 2019-20-4] Dostupné z: https://www.internationalphoneticassociation.org/icphs-proceedings/ICPhS1999/papers/p14_0269.pdf
- [8] MEKYSKA, Jiří. *Analýza řečových promluv pro IT diagnostiku neurologických onemocnění* [online]. Vysoké učení technické v Brně. Fakulta elektrotechniky a komunikačních technologií, 2014 [cit. 2018-12-10]. Dostupné z: <http://hdl.handle.net/11012/35772>. Disertační práce. Vysoké učení technické

- v Brně. Fakulta elektrotechniky a komunikačních technologií. Ústav telekomunikací. Vedoucí práce Zdeněk Smékal.
- [9] FAHN, S. a R. ELTON: *Recent developments in Parkinson's disease*, kapitola Unified Parkinson's Disease Rating Scale. Macmillan, 1987, s. 153–163.
- [10] MathWorks™, *Matlab User's Guide*, část Funkce – Deskriptivní statistika, 2018, Dostupné z: <https://www.mathworks.com/help/matlab/functionlist.html#bs5838u-4>
- [11] BEDÁŇOVÁ, Iveta. *Biostatistika: Nelineární korelační závislost* [online]. [cit. 2018–14–12]. Dostupné z: <https://cit.vfu.cz/stat/FVL/Teorie/Predn5/nelinear.htm>. Prezentace. Veterinární a farmaceutická univerzita Brno.
- [12] BROWNLEE, Jason. *Difference Between Classification and Regression in Machine Learning* [online]. 11. 12. 2017 [cit. 2019–05–12]. Dostupné z: <https://machinelearningmastery.com/classification-versus-regression-in-machine-learning/>
- [13] KOHAVI, Ron. A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. *International Joint Conference on Artificial Intelligence* [online]. Stanford University, 1995, , 1137–1143 [cit. 2019–05–12]. Dostupné z: <http://robotics.stanford.edu/%7Eronnyk/accEst.pdf>
- [14] BREIMAN, Leo. *Classification and regression trees*. Belmont, Calif.: Wadsworth International Group, c1984. ISBN 0534980538.
- [15] BARATLOO, A., HOSSEINI, M., NEGIDA, A., a E. ASHAL, G. (2015). Part 1: Simple Definition and Calculation of Accuracy, Sensitivity and Specificity. *Emergency (Tehran, Iran)*, 3(2), 48–49. Dostupné z: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4614595/>
- [16] POWERS, David. *Evaluation: From Precision, Recall and F-Factor to ROC, Informedness, Markedness & Correlation* [online]. Adelaide, 2007 [cit. 2019–05–13]. Dostupné z: http://www.flinders.edu.au/science_engineering/fms/School-CSEM/publications/tech_reps-research_artfcts/TRRA_2007.pdf. Technická zpráva. School of Informatics and Engineering, Flinders University.
- [17] CHAI, T. a R. R. DRAXLER. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. *Geoscientific Model Development* [online]. 2014, 7(3), 1247–1250 [cit. 2019–05–13]. DOI: 10.5194/gmd-7-1247-2014. ISSN 1991–9603. Dostupné z: <https://www.geosci-model-dev.net/7/1247/2014/>
- [18] RAMACHANDRAN, K. M. a Chris P. TSOKOS. *Mathematical statistics with applications*. Boston: Academic Press, c2009. ISBN 9780123748485. Dostupné z: <http://elearn.luanar.ac.mw/odl/public/Files/Mathematical%20statistics%20with%20applications.pdf>

- [19] EFRON, Bradley. Estimating the Error Rate of a Prediction Rule: Improvement on Cross-Validation. *Journal of the American Statistical Association* [online]. 1983, **78**(382) [cit. 2019-05-13]. DOI: 10.2307/2288636. ISSN 01621459. Dostupné z: <https://www.jstor.org/stable/2288636?origin=crossref>
- [20] SMITH, Martha. *Overfitting* [online]. University of Texas at Austin, 2014 [cit. 2019-05-13]. Dostupné z: <https://web.ma.utexas.edu/users/mks/statmistakes/overfitting.html>

Seznam použitých zkratek a veličin

3F – faciokineze + fonetika + fotorespirace

ACC – accuracy

CART – classification and regression trees

$CSADf_0$ – kumulativní součet absolutních diferencí základního kmitočtu signálu

$CSADE$ – kumulativní součet absolutních diferencí krátkodobé energie signálu

cTree – classification tree

DX – dysartrický index

E – krátkodobá energie signálu

FN – false negative

FP – false positive

f_0 – základní kmitočet signálu

f_s – vzorkovací kmitočet signálu

GP – globální parametr

HD – hypokinetická dysartrie

IR – intonace řeči

L-DOPA – levodopa (L-3,4-dihydroxyphenylalanin)

LED – levodopa equivalent dose

MAE – mean absolute error

MCC – Matthew's correlation coefficient

MPP+ – 1-methyl-4-fenylpyridinium

MPTP – 1-methyl-4-fenyl-1,2,3,6-tetrahydropyridin

MSE – mean squared error

PARCZ – Czech Parkinsonian speech database

PN – Parkinsonova nemoc

REE – relative estimation error

RMSE – root mean squared error

SCR – score

SEN – sensitivity

SNR – signal-to-noise ratio

SPE – specificity

SPLAB – signal processing laboratory

TN – true negative

TNSR – total-to-net speech rate

TP – true positive

TSS – true skill statistic

UPDRS III – Unified Parkinson’s disease rating scale, part 3

UPDRS IV – Unified Parkinson’s disease rating scale, part 4

USRC – universal speech rate constant

Seznam příloh


A	Jádrové odhady hustoty pravděpodobnosti pro zbylé skupiny parametrů.....	59
B	Obsah CD.....	62

Seznam obrázků v příloze


Obr. A: Rozložení hustoty pravděpodobnosti pro mezikvartilní rozsah variability základního kmitočtu.	59
Obr. B: Rozložení hustoty pravděpodobnosti pro počet špiček variability krátkodobé energie.	59
Obr. C: Rozložení hustoty pravděpodobnosti pro variační koeficient monokmitočtu.	60
Obr. D: Rozložení hustoty pravděpodobnosti pro směrodatnou odchylku monohlasitosti.	60
Obr. E: Rozložení hustoty pravděpodobnosti pro universal speech rate constant.	61
Obr. F: Rozložení hustoty pravděpodobnosti pro globální parametr v závislosti na celkovém čase.	61

A Jádrové odhady hustoty pravděpodobnosti pro zbylé skupiny parametrů


V této příloze je obsaženo 6 vybraných grafů jádrového odhadu hustoty pravděpodobnosti pro každou ze skupin, které nebyly obsaženy v kap. 6.3.




Obr. A: Rozložení hustoty pravděpodobnosti pro mezikvartilní rozsah variability základního kmitočtu.




Obr. B: Rozložení hustoty pravděpodobnosti pro počet špiček variability krátkodobé energie.




Obr. C: Rozložení hustoty pravděpodobnosti pro variační koeficient monokmitočtu.



Obr. D: Rozložení hustoty pravděpodobnosti pro směrodatnou odchylku monohlasitosti.



Obr. E: Rozložení hustoty pravděpodobnosti pro universal speech rate constant.



Obr. F: Rozložení hustoty pravděpodobnosti pro globální parametr v závislosti na celkovém čase.

B Obsah CD

Na přiloženém CD je vypálena kompletní programová dokumentace diplomové práce, všechny výsledné tabulky, všechny výsledné grafy a jedna samostatná textová verze práce ve formátu .pdf. Všechny tyto soubory jsou také přiloženy k elektronické verzi práce v jednom souboru diplomova_prace.zip. Soubory jsou strukturovány do složek a několika volně vložených .m souborů (hlavní soubory práce). Pokud by některý z volně vložených skriptů nechtěl fungovat, většinou se jedná o problém, že nedokáže nalézt podsoubory, které využívá, nebo tabulky, jejichž hodnoty používá. V takovém případě stačí tento skript, všechny podsoubory, které využívá a danou tabulku dát do složky na stejnou úroveň.

- 1. Volně vložené skripty pro Matlab** – DP_výpočet_všech_parametrů.m – hlavní soubor pro výpočet všech konvenčních i nových parametrů. Využívá všechny podsoubory ze složek *konvenční parametry* a *nové parametry*. Obsahuje nastavení váhovacího okna. Klasifikacni_analyza.m – slouží k provedení klasifikace, obsahuje výběr parametrů skrz výběr sloupců ve feat_data a výběr nastavení analýzy skrz sett._. Používá několik podsouborů ze složky toolbox. Klasifikacni_analyza_vsechno.m – přepracovaný předchozí skript, pro výpočet klasifikace pro všechna data najednou. Korelace.m – skript pro provedení korelační analýzy, obsahuje výběr parametrů skrz výběr sloupců feat_data a použitých škál skrz výběr sloupců clin_data, dále nastavení typu korelace a řádu křivky. Používá skript correlation_analysis.m ze složky podsoubory. Out_with_outliers.m – slouží ke zjištění, kteří řečníci jsou „outliery“ u několika parametrů zároveň. Regresni_analyza.m – slouží k provedení regresní analýzy, umožňuje nastavení stejným způsobem, jako u klasifikacni_analyza.m. regresni_analyza_vsechno.m – opět předělaný předchozí skript, provádí regresní analýzu pro všechna data najednou. Sffs_klasifikace – provádí sekvenční výběr parametrů pro klasifikaci, obsahuje nastavení vstupních parametrů skrz sloupce v data, normalizaci skrz nastavení normalize a nastavení klasifikačního algoritmu, křížové validace, metrik, maximálního počtu najednou použité kombinace parametrů a počtu parametrů, po jejichž přidání do kombinace a následném nezlepšení, se klasifikátor vrátí na předchozí nejlepší kombinaci skrz nastavení sett._. Využívá skript SFFS_cls.m ze složky toolbox. Sffs_regrese.m – provádí sekvenční výběr parametrů pro regresní analýzu, obsahuje výběr parametrů skrz sloupce ve feat_data a výběr metrik skrz sloupce v clin_data. Ostatní nastavení jsou stejná, jako u sffs_klasifikace.m. Tento skript používá skript SFFS_reg.m ze složky toolbox. Statistika.m – počítá v této práci používané statistické veličiny pro jednotlivé parametry. Vypocet_hustoty_pravdepodobnosti.m – slouží k výpočtu a vykreslení grafů hustoty

pravděpodobnosti, využívá skript `kernel_densityPlot.m` ze složky *podsubory*.

2. **Složka konvenční parametry** – obsahuje výpočty všech konvenčních parametrů a dále obsahuje podsložku *external* se sbírkou externích funkcí, které jsou používány k výpočtu (především zmíněné funkce `energy.m` a `praat_F0.m`).
3. **Složka nové parametry** – obsahuje `.m` soubory pro výpočet všech nových parametrů a stejnou podsložku externích podsuborů, jako předchozí složka.
4. **Složka podsubory** – obsahuje externí podsubory, pro výpočet korelační analýzy a vykreslení grafů hustoty pravděpodobnosti.
5. **Složka toolbox** – obsahuje všechny podsubory potřebné pro výpočet klasifikační analýzy, regresní analýzy i sekvenčního výběru parametrů o obou.
6. **Složka Výsledné grafy** – obsahuje všechny grafy hustoty pravděpodobnosti, všechny grafy korelační analýzy a také všechny grafy průběhu výběru parametrů u sekvenčního výběru.
7. **Složka Výsledné tabulky** – obsahuje v tabulkách všechny výsledky práce. Podsložka *výsledky sffs* obsahuje formou souborů formátu výsledků z Matlab (`.mat`) pro každou ze škál a klasifikaci 2 struktury, jednu s výsledky (out) a druhou s jednotlivými provedenými změnami (var – tento je vykreslován do grafů). Soubory `hodnoty_parametru.xlsx` a `hodnoty_parametru_regrese_bez_DX_outliera.xlsx` jsou názvy tabulek s vypočtenými hodnotami všech parametrů pro všechny řečníky (+ jejich medicínská metadata). Vypočtené hodnoty parametrů a hodnoty medicínských škál v těchto dvou souborech jsou vstupem do všech `.m` souborů, kde se provádí nějaká analýza. Dále složka obsahuje soubor `korelační_analýza.xlsx` s výsledky ρ a p u korelační analýzy pro všechny parametry (výsledky pro jednotlivé škály jsou na samostatných záložkách). Soubor `vysledky_klasifikacni_a_regresni_analyzy.xlsx` obsahuje na pěti záložkách výsledky klasifikace a čtyř regresních analýz pro všechny parametry. `Vysledky_klasifikacni_a_regresni_analyzy_pro_vsechny.xlsx` pak obsahuje stejnou formou výsledky při analýze, kdy byla použita všechna data najednou.